

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

**ALAN LUCAS DOS SANTOS**

**USO DE REDE NEURAL PARA DESENVOLVIMENTO  
DE SISTEMA ESPECIALISTA PARA DIAGNOSE DE  
DOENÇAS FOLIARES EM EUCALIPTO**

SOROCABA  
2021

**ALAN LUCAS DOS SANTOS**

**USO DE REDE NEURAL PARA DESENVOLVIMENTO  
DE SISTEMA ESPECIALISTA PARA DIAGNOSE DE  
DOENÇAS FOLIARES EM EUCALIPTO**

Dissertação apresentada ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis (PPGPUR-So) da Universidade Federal de São Carlos (UFSCar), Campus Sorocaba, como parte dos pré-requisitos para obtenção do título de Mestre em Produção Sustentável

SOROCABA  
2021

Santos, Alan Lucas dos

Uso de rede neural para desenvolvimento de sistema especialista para diagnose de doenças foliares em eucalipto / Alan Lucas dos Santos -- 2021.  
60f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba  
Orientador (a): Waldir Cintra de Jesus Junior  
Banca Examinadora: Edival Ângelo Valverde Zauza,  
William Bucker Moraes  
Bibliografia

1. Inteligência Artificial. 2. Sistema Especialista. 3. Doenças Foliares do Eucalipto. I. Santos, Alan Lucas dos. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática  
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -  
CRB/8 6979



# UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências e Tecnologias Para a Sustentabilidade  
Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis

---

## Folha de Aprovação

---

Defesa de Dissertação de Mestrado do candidato Alan Lucas dos Santos, realizada em 24/06/2021.

### Comissão Julgadora:

Prof. Dr. Waldir Cintra de Jesus Junior (UFSCar)

Prof. Dr. Willian Bucker Moraes (UFES)

Prof. Dr. Edival Ângelo Valverde Zauza (Suzano Papel e Celulose)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis.

## SUMÁRIO

|  |     |
|--|-----|
| RESUMO .....   | i   |
| SUMMARY .....  | iii |
| 1-INTRODUÇÃO .....   | 1   |
| 1.1- OBJETIVO.....   | 2   |
| 2 - REVISÃO DE LITERATURA .....  | 2   |
| 2.1 - Setor florestal .....  | 2   |
| 2.2 - Importância das doenças do eucalipto e diagnose.....                     | 2   |
| 2.3 - Visão computacional .....  | 3   |
| 2.3.1 – Imagens Generalizadas .....  | 4   |
| 2.3.2 – Segmentação de imagens.....  | 6   |
| 2.3.3 – Representações geométricas .....                                       | 6   |
| 2.3.4 – Modelos relacionais.....   | 7   |
| 2.4 - Sistemas baseados em visão computacional .....                           | 8   |
| 2.4.1 – Fluxo de um sistema baseado em visão computacional .....               | 9   |
| 2.5 - Imagens digitais .....   | 10  |
| 2.5.1 - Elementos da percepção visual .....                                    | 10  |
| 2.5.2 - Formação de imagem .....   | 12  |
| 2.5.3 - Representação de imagem digital.....                                   | 13  |
| 2.6 - Inteligência artificial .....  | 14  |
| 2.6.1 - Treinamento ou aprendizado de máquina ( <i>machine learning</i> )..... | 14  |
| 2.6.2 -Tipos de aprendizado de máquina.....                                    | 16  |
| 2.7 - Redes Neurais artificiais.....   | 18  |
| 2.7.1 - O Neurônio biológico.....  | 18  |
| 2.7.2 - O Neurônio artificial .....  | 19  |
| 2.7.3 - Modelo de um neurônio .....  | 20  |
| 2.8 - Arquiteturas de redes Neurais .....                                      | 21  |
| 2.8.1 - Rede Alimentada adiante com camada única.....                          | 21  |
| 2.8.2 - Redes Alimentadas adiante com múltiplas camadas.....                   | 22  |
| 2.8.3 - Redes recorrentes .....  | 23  |
| 2.9 - Perceptron .....   | 24  |
| 2.9.1 - Perceptron multicamada e retropropagação .....                         | 26  |
| 3 - MATERIAL & MÉTODOS.....  | 27  |
| 3.1 - Linguagem de programação .....   | 27  |
| 3.2 - Aquisição de imagens .....   | 28  |
| 3.3 - Processamento das imagens .....  | 29  |
| 3.3.1 – Segmentação por binarização .....                                      | 29  |
| 3.4 – Planejamento e desenvolvimento da rede neural.....                       | 31  |
| 3.4.1 – Normalização dos dados.....  | 32  |
| 3.4.2 - Topologias da Rede Neural Artificial .....                             | 32  |
| 3.5 - Testes e homologação da Rede Neural Artificial.....                      | 34  |
| 3.5.1 – Desempenho da RNA .....  | 35  |
| 3.5.1.1 - Acurácia .....   | 35  |
| 3.5.1.2 - Precisão .....   | 35  |
| 3.5.1.3 - Revogação .....  | 35  |
| 3.5.1.4 - F1 score .....   | 36  |
| 4 - RESULTADOS E DISCUSSÃO .....   | 36  |
| 4.1 – Topologia 1 – 256 Neurônios .....  | 37  |
| 4.2 – Topologia 2 – 86 neurônios .....   | 39  |

|   |    |
|---|----|
| 4.3 – Topologia 3 – 173 neurônios .....     | 41 |
| 4.4 – Topologia 4 – 509 neurônios .....     | 43 |
| 4.5 – Topologia 5 – 513 neurônios .....     | 45 |
| 4.6 – Topologia 6 – 195 neurônios .....     | 47 |
| 4.7 – Topologia 7 – 291 neurônios .....     | 49 |
| 4.8 – Topologia 8 – 1526 neurônios .....    | 51 |
| 4.9 - Comparações entre as topologias ..... | 53 |
| 4.10 – Ambiente de execução do sistema..... | 53 |
| 5 - Conclusão .....                         | 56 |
| 6 - Considerações finais.....               | 57 |
| 7 - REFERÊNCIAS BIBLIOGRÁFICAS.....         | 58 |

## RESUMO

Após o crescimento da criação e armazenamento de dados, que são a matéria prima da inteligência artificial, nos últimos anos se nota que em quase toda indústria e setores da saúde já trabalham com softwares de inteligência artificial, os quais são utilizados principalmente no auxílio de automação, análises de fraude, diagnose de doenças humanas, marketing digital, carros autônomos, redes sociais, dentre outros. Porém, no setor agroflorestal, responsáveis por grande parte do PIB econômico brasileiro, são escassos os trabalhos, softwares e informações relacionados a inteligência artificial. Objetivou-se com o presente trabalho é criar um sistema com base em redes neurais artificiais (RNA) para detecção de doenças foliares do eucalipto, capaz de realizar o processamento digital da imagem mediante a utilização de técnicas de visão computacional e treinamento de uma rede neural com a arquitetura *Perceptron* multicamadas utilizando o algoritmo de treinamento *Backpropagation*, por meio da linguagem de programação Python. O presente trabalho foi desenvolvido com a coleta de folhas com manchas foliares de *Mycosphaerella* e ferrugem do eucalipto (*Austropuccinia psidii*), além de folhas saudias para a criação do *dataset* para treinamento da Rede Neural Artificial (RNA) *perceptron* multicamadas (MLP) com o algoritmo de *backpropagation*. As folhas foram digitalizadas e submetidas ao primeiro processo realizado pelo sistema especialista, transformando as imagens coloridas em tons de cinza, diminuindo de três dimensões de cores (RGB) para apenas uma dimensão, foi realizada a padronização da largura da folha e redimensionamento de sua altura sem a perda de proporção da imagem e por fim a binarização para extração apenas do objeto de interesse, gerando um histograma com as frequências de tons de cinza que foi utilizado como dado de entrada para a rede neural para treinamento e validação. Foram propostas oito topologias de Redes

Neurais Artificiais contendo quatro topologias com uma camada oculta de neurônios e quatro topologias com a com duas camadas ocultas de neurônios. Todas as topologias obtiveram em média de 92% de acertos, sendo considerada a mais adequada à topologia com apenas uma camada com 86 neurônios pela média dos melhores resultados obtidos das métricas de acurácia, precisão, revogação e *F1 Score* acima dos 93% e o baixo esforço computacional para a diagnose da folha o que garante um melhor desempenho do Sistema especialista desenvolvido.

Palavras chave: *Eucalyptus* spp., manchas foliares, Inteligência Artificial, *Perceptron* multicamadas, Redes neurais, Visão computacional.

## SUMMARY

After the growth of data creation and storage, which are the raw material of artificial intelligence, in recent years it has been noticed that almost every industry and health sector already works with artificial intelligence software, which are used mainly to aid automation, fraud analysis, diagnosis of human diseases, digital marketing, autonomous cars, social networks, among others. However, in the agroforestry sector, responsible for a large part of the Brazilian economic GDP, work, software and information related to artificial intelligence are scarce. The objective of this work is to create a system based on artificial neural networks (ANN) for detection of eucalyptus leaf diseases, capable of performing digital image processing using computer vision techniques and training a neural network with the multilayer Perceptron architecture using the Backpropagation training algorithm, through the Python programming language. The present work was developed with the collection of leaves with *Mycosphaerella* leaf spots and eucalyptus rust (*Austropuccinia psidii*), as well as healthy leaves for the creation of the dataset for training the Artificial Neural Network (ANN) multilayer perceptron (MLP) with the algorithm of backpropagation. The sheets were scanned and submitted to the first process carried out by the expert system, transforming the color images into grayscale, reducing from three color dimensions (RGB) to just one dimension, standardizing the width of the sheet and resizing its height without loss of image proportion and finally binarization to extract only the object of interest, generating a histogram with grayscale frequencies that was used as input to the neural network for training and validation. Eight topologies of Artificial Neural Networks were proposed, containing four topologies with one hidden layer of neurons and four topologies with the one with two hidden layers of neurons. All topologies had an average of 92% hits, being considered the most suitable for the topology with only one layer with 86 neurons by the average of the best results obtained from the

accuracy, precision, recall and F1 Score metrics above 93% and the low computational effort for leaf diagnosis which guarantees a better performance of the developed expert system.

**Keywords:** *Eucalyptus* spp., leaf diseases, Artificial Intelligence, Multilayer Perceptron, Neural networks, Computer vision.

## 1-INTRODUÇÃO

O setor florestal tem 10 milhões de hectares de florestas plantadas, sendo de eucalipto que corresponde a 7,6 milhões de hectares e de pinus 2 milhões de hectares (IBGE, 2020). O eucalipto é cultivado para diversos fins, como reflorestamento, papel, celulose, carvão, óleo para indústrias farmacêuticas, dentre outros, garantindo grande importância comercial na economia brasileira com impacto significativo no PIB, nas exportações e na geração de empregos.

As doenças da cultura do Eucalipto têm grande importância econômica causando grandes perdas sendo uma das principais preocupações do produtor rural (PASSADOR et al., 2021). O eucalipto é afetado por vários patógenos desde a fase de viveiro até o plantio adulto, ocorrendo nos mais variados locais, espécies e épocas do ano, os quais podem comprometer completamente a produção e a qualidade da madeira. A quantificação das doenças normalmente é feita visualmente, por pessoas especializadas e/ou treinadas (VALE et al., 2004; ALFENAS et al., 2009), o que demanda recurso humano, financeiro e tempo.

No manejo integrado de doenças há necessidade de identificação de forma rápida para evitar maiores danos econômicos e o diagnóstico feito através de um sistema especialista utilizando uma inteligência artificial para identificação da doença, permite uma tomada de decisão mais rápida, reduzindo tempo de identificação e demanda de especialistas utilizados no processo de identificação (GANESAN, 2004), podendo ser feito a análise no local da coleta.

A RNA tem um papel importante dentro de um sistema especialista, sendo o mecanismo de inferência (análise feita através da base de conhecimento), sendo uma das principais ferramentas utilizadas para classificação de padrões, por sua capacidade de generalização e constante evolução a partir do aumento de sua base de conhecimento, auxiliando dessa forma a diagnose através de imagens como criado por (FUENTES et al., 2017), na qual é feito a detecção de pragas e doenças do tomate em tempo real a partir de uma RNA.

Nesse sentido é crescente a necessidade de soluções aliadas à tecnologia da informação no agronegócio em busca de eficiência, redução de custos, tempo e menor impacto ambiental.

Com o progresso da tecnologia pode-se utilizar as Redes Neurais Artificiais (RNA) para auxílio na diagnose de doenças, por meio da diferenciação e classificação, processamento de imagens e reconhecimento de padrões.

## **1.1- OBJETIVO**

O presente trabalho tem como objetivo o desenvolvimento de um sistema especialista para análise e reconhecimento de padrões das doenças foliares do eucalipto.

## **2 - REVISÃO DE LITERATURA**

### **2.1 - Setor florestal**

O setor florestal tem grande importância na economia do país e o eucalipto tem grande participação no setor, onde representa 76,3 dos 10 milhões de hectares de florestas plantadas (IBGE, 2020).

O setor de árvores plantadas tem um impacto de 1,2% no PIB nacional, só no ano de 2019 a indústria de base florestal fechou o ano com superávit de US\$10,3 bilhões, o segundo melhor resultado dos últimos 10 anos, sendo responsável por 3,75 milhões de empregos diretos e indiretos (IBA, 2020).

Nesse contexto, no cultivo do eucalipto existem diversos fatores que afetam e limitam sua produtividade, gerando um enorme impacto econômico, e as doenças tem um destaque especial (REZENDE et al., 2019), dessa forma são necessárias ações e medidas para identificar e controlar as de doenças do eucalipto da fase de viveiro até o plantio adulto .

### **2.2 - Importância das doenças do eucalipto e diagnose**

O eucalipto é afetado por inúmeros patógenos/doenças, os quais podem causar danos da ordem de até 100% caso estratégias adequadas de manejo não sejam implementadas (ALFENAS et al., 2009; MAFFIA et al., 2014). Os sintomas visuais podem ser detectados pela mudança na aparência da planta como cores, formas, manchas e lesões que pode indicar o ataque de alguma doença ou praga, na qual, uma inspeção visual pode ser utilizada para identificar e mensurar a incidência e severidade da doença (VELÁSQUEZ et al., 2020). O primeiro passo na implementação do manejo integrado de doenças (MID) envolve a diagnose correta do agente causal/doença, para posteriormente se efetuar a sua quantificação, a qual é fundamental tanto para o estudo de estratégias de manejo, na determinação da eficiência de fungicidas/ produtos biológicos/resistência varietal, como para a definição de curvas de progresso e determinação dos danos e perdas (JESUS JUNIOR et al., 2004). Apesar da importância da quantificação de doenças ser amplamente reconhecida, os métodos

tradicionais de detecção de doenças são dependentes da observação manual e consequentemente levam a uma baixa eficiência de detecção e pouca confiabilidade, existe falta de padronização nos métodos utilizados na avaliação de doenças, o que pode interferir negativamente nos passos posteriores do MID (ZHANG, 2020).

A detecção e classificação de doenças por imagens é uma área de pesquisa que está crescendo cada vez mais no setor agrícola, criando um tipo de automação padronizado que é uma grande vantagem para os agricultores (BATMAVADY; SAMUNDEESWARI, 2019)

Visando contornar tais problemas há a possibilidade de se empregar a inteligência artificial, a qual tem sido utilizada com sucesso em inúmeras outras áreas, porém na área de patologia florestal são extremamente escassos os trabalhos desenvolvidos.

### **2.3 - Visão computacional**

Segundo Ballard e Brown (1982) a visão computacional tem o objetivo de construir descrições explícitas e significativas de objetos físicos a partir de imagens, dado que a compreensão de uma imagem é completamente diferente do seu processamento.

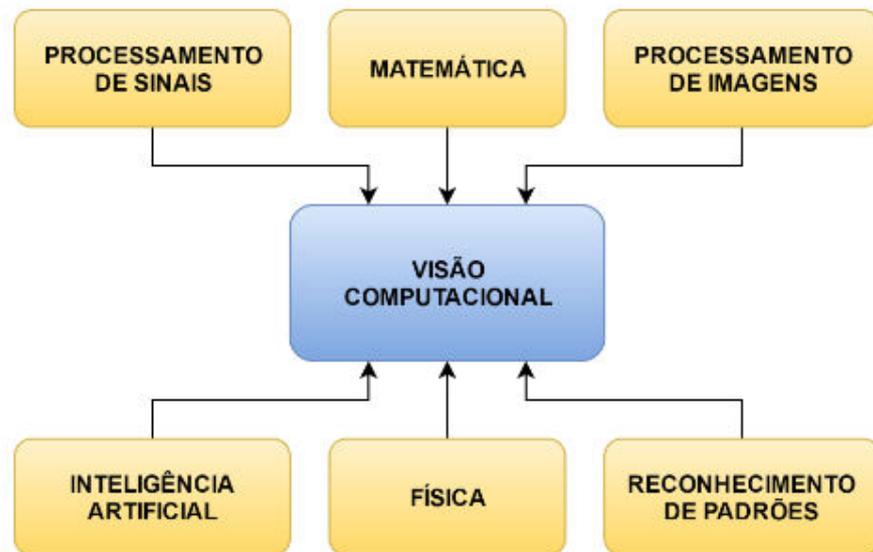
A visão computacional é a ciência que estuda e desenvolve tecnologias que possibilitam que as máquinas e algoritmos consigam visualizar e captar as características do meio, através de sensores e dispositivos e, a partir das informações extraídas, podemos reconhecer, manipular e processar dados sobre todos os objetos que existem na imagem capturada.

Na percepção visual existe a relação da entrada visual com modelos que existem no mundo e com isso tem-se uma lacuna entre a imagem e um modelo (ideias, conceitos) que podem explicar, descrever e abstrair as informações de uma imagem. Os sistemas de visão computacional possuem métodos que conectam uma entrada de uma imagem com uma saída. Essa saída seria uma descrição final, decisão ou interpretação da imagem, de modo que a visão computacional utiliza algoritmos para construir essas representações que são divididas em imagens Generalizadas, segmentadas, geométricas e relacionais (BALLARD; BROWN, 1982).

A visão computacional fez grandes avanços nos últimos anos, principalmente o reconhecimento de objetos para utilização em Redes Neurais Artificiais (MOHANTY; HUGHES; SALATHÉ, 2016). Segundo Barelli (2018) existe diversos campos de pesquisa que contribuem e estão fortemente relacionados à visão computacional (Figura 1), como a neurobiologia que estuda os sistemas biológicos de visão, a inteligência artificial

principalmente aplicada a área de robótica, onde é necessário fornecer informações referente ao ambiente para o robô, o processamento de imagens e o reconhecimento de padrões que estão mais fortemente relacionados a visão computacional potencializando a manipulação e identificações de informações representadas.

**Figura 1** – Campos de estudo interligados a visão computacional.



Fonte: Barelli (2018).

### 2.3.1 – Imagens Generalizadas

Imagens Generalizadas são representações icônicas, ou seja, semelhantes a imagens (Figura 2), e são relativos à entrada de dados em um sistema de computação visual. As imagens podem surgir de diversos tipos de equipamentos e tecnologias e podem revelar aspectos de propriedades físicas da cena que foram retiradas como orientações de superfície, alcance e refletância (BALLARD; BROWN, 1982).

**Figura 2** –Imagem Generalizada, representação digital de uma paisagem física



**Fonte: Ballard e Brown (1982).**

Existem diversos aparelhos utilizados para a aquisição e captura de imagens (Figura 3), sendo que alguns imagens a partir de ambientes onde não existe luz, como aparelhos de Raio-X e Ultrassom.

**Figura 3** – Exemplos de dispositivos utilizados para a aquisição de imagens, como Câmera digital (A), Aparelho de Ultrassom (B), Câmera Termográfica (C), Leitor de Código de barra (D), Scanner digital(E) e aparelho de radiografia(F).



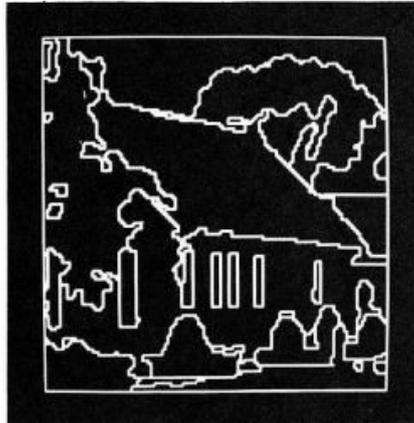
**Fonte: Barelli (2018).**

Segundo Barelli (2018), a visão computacional procura imitar a natureza humana, mas existia a dificuldade de desenvolver um modelo para essa representação, pois não se tinha informações suficientes sobre como as imagens são interpretadas no cérebro humano. Entretanto, atualmente são desenvolvidas pesquisas com o intuito de aprender e entender o funcionamento do cérebro para ser aplicado no desenvolvimento tecnológico da visão computacional.

### 2.3.2 – Segmentação de imagens

Imagens segmentadas são formadas a partir das imagens generalizadas utilizando-se softwares para reunir ou destacar elementos significativos dentro de uma imagem com o objetivo de realçar bordas, a fim de identificar os objetos representados em uma imagem (Figura 4). Esse recurso é importante tanto para economizar processamento computacional quanto para a remoção de ruídos e dados inadequados em uma imagem (BALLARD; BROWN, 1982; BARELLI, 2018).

**Figura 4** – Imagem segmentada, imagem contendo o realce das bordas de todos os objetos nela identificados a partir da descontinuidade ou similaridade de regiões.

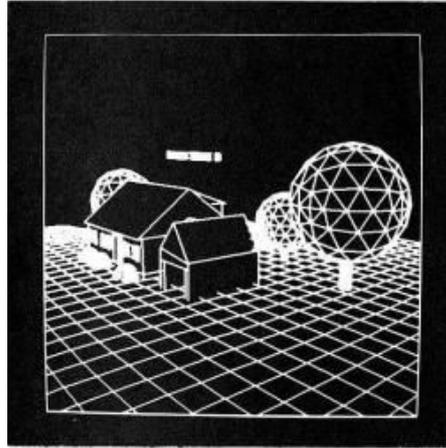


Fonte: Ballard e Brown (1982).

### 2.3.3 – Representações geométricas

Representações geométricas são utilizadas para pegar características e ideias de forma bidimensional e tridimensional (Figura 5), porém a quantificação dessas formas requer muito poder computacional para o seu processamento, pois existem efeitos de iluminação e movimento que precisam ser processados, tornando assim o uso dessa técnica em circunstâncias mais específicas (BALLARD; BROWN, 1982).

**Figura 5** – Imagem geométrica, imagem gerada a partir de uma imagem digital utilizando a identificação de objetos pela quantidade de intersecções a partir da continuidade e similaridade de regiões.

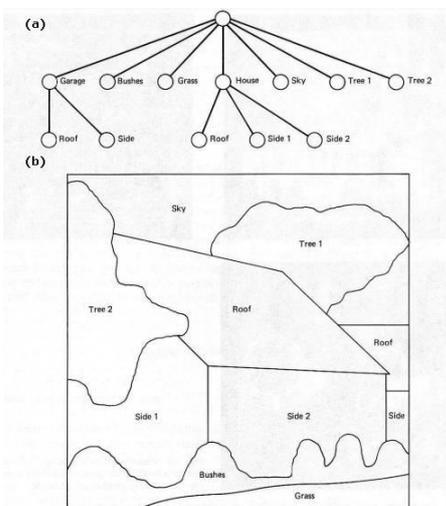


Fonte: Ballard e Brown (1982).

### 2.3.4 – Modelos relacionais

Modelos relacionais são modelos complexos de representações de alto nível (Figura 6b), que demandam muito processamento computacional sendo necessário conhecimento prévio e modelos adquiridos do assunto a ser tratado antes de uma experiência perceptiva. Uma ferramenta importante nesse conceito é a utilização de redes semânticas (Figura 6a), para representação e organização desse conhecimento prévio na elaboração e utilização deste modelo (BALLARD; BROWN, 1982).

**Figura 6** – Representação de Modelo relacional: (a) redes semânticas utilizadas para representação do modelo;(b) modelo relacional feito a partir de uma imagem generalizada.



Fonte: Ballard e Brown (1982).

## 2.4 - Sistemas baseados em visão computacional

Hoje em dia quase que todas as tarefas que realizamos manualmente podem ser automatizadas por sistemas de visão computacional. Como exemplos tem-se sistemas de vigilância, porteiros eletrônicos que detectam se a pessoa é um morador do condomínio ou não, braços robóticos em montadoras que fazem a montagem de partes do veículo sem nenhuma intervenção humana e mais recentemente a indústria automobilística está aplicando visão computacional (Figura 7) para a construção de carros autônomos, inteligentes, para tráfego sem a intervenção humana, sendo capaz de rastrear e detectar pessoas, placas, ruas e outros objetos (BARELLI, 2018).

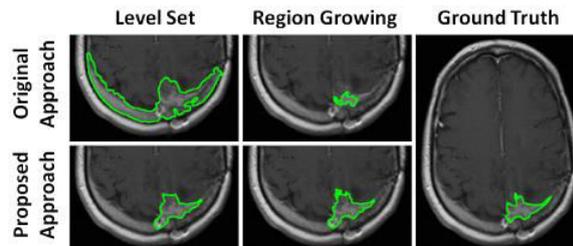
**Figura 7** – Imagem de um veículo autônomo: (a) motorista dentro de um veículo autônomo em movimento; (b) objeto capturado pela câmera traseira esquerda do veículo; (c) detecção de veículos, faixas de rua e placas pela câmera frontal do veículo.



Fonte: Barelli (2018).

No campo da saúde humana os sistemas de visão computacional estão sendo empregados com êxito em várias áreas. Essa tecnologia, aliada a técnicas de aprendizagem de máquina, permite que os modelos criados possam aprender e aperfeiçoar uma tarefa específica, tornando-se um sistema especialista em detecção de anomalias de exames por imagem (Figura 8), como: tomografia computadorizada, ressonância magnética, ultrassom dentre outros. Essas ferramentas são extremamente importantes, pois podem auxiliar no diagnóstico precoce de doenças (BARELLI, 2018).

**Figura 8** – Resultados da segmentação de uma imagem de ressonância magnética de um tumor cerebral usando os dois métodos de segmentação para uma comparação direta da abordagem original e a abordagem proposta por Reddy; Solmaz; Yan et al. (2012). Os contornos verdes representam as regiões tumorais.



Fonte: Reddy; Solmaz; Yan *et al.* (2012).

Apesar de ser utilizado em diversas áreas, empregando-se vários tipos de linguagens de programação e algoritmos, os sistemas de visão computacional partilham de um fluxo comum ou sequencia de processos como aquisição de imagem, pré-processamento, extração das características, reconhecimento de padrões e classificação (Figura 9), utilizando as técnicas e modelos acima mencionados (BARELLI, 2018; UDAWANT; SRINATH, 2019).

**Figura 9** – Fluxo de um sistema baseado em visão computacional

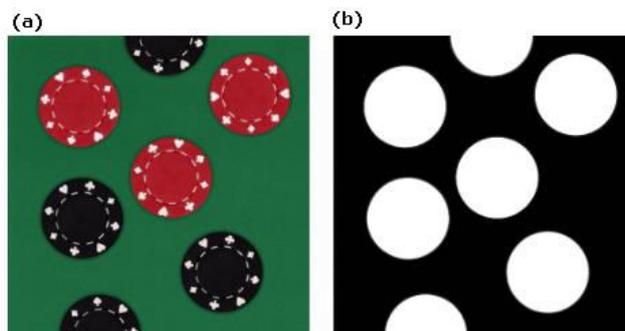


Fonte: Barelli (2018).

#### 2.4.1 – Fluxo de um sistema baseado em visão computacional

A primeira etapa de todo sistema de visão computacional é a aquisição da imagem, seja ela inerente ao sistema ou imputada por terceiros. A imagem capturada pode estar configurada como bidimensional, tridimensional ou uma sequência de imagens como ocorre em vídeos. Após a imagem digitalizada (Figura 10a), é realizada a segunda etapa que consiste no pré-processamento, em que se utilizam técnicas para evidenciar a região ou o objeto de interesse (Figura 10b). Após a definição dos objetos ou características de interesse pode-se utilizar técnicas na imagem para destacar bordas e formas geométricas e tratamento de ruídos que podem influenciar no resultado final. Assim, é possível realizar vários tipos de tratamentos na imagem (BARELLI, 2018).

**Figura 10** – Imagens digitais: (a) Imagem digital generalizada; (b) imagem gerada após o pré-processamento utilizando binarização.



Fonte: Barelli (2018).

Após as regiões de interesse estarem devidamente segmentadas aplicam-se algoritmos para a extração de características de interesse, como forma geométrica, saturação de cor, tamanho, dentre outras, para poder diferenciar o objeto ou área de interesse do restante da imagem. A última etapa se baseia no processamento de alto nível, com o intuito de reconhecer o objeto segmentado através de suas características, definindo-o em uma determinada classe de saída, validando e avaliando se os resultados são satisfatórios (BARELLI, 2018).

## 2.5 - Imagens digitais

Segundo Gonzales e Woods (2009) uma imagem pode ser definida como uma função bidimensional,  $f(x,y)$ , na qual  $x$  e  $y$  são coordenadas espaciais definindo um plano, e a amplitude dessa função em qualquer ponto de  $(x, y)$  é denominado como intensidade ou nível de cinza. Assim, quando tem-se esses valores discretos e finitos, denomina-se de imagem digital.

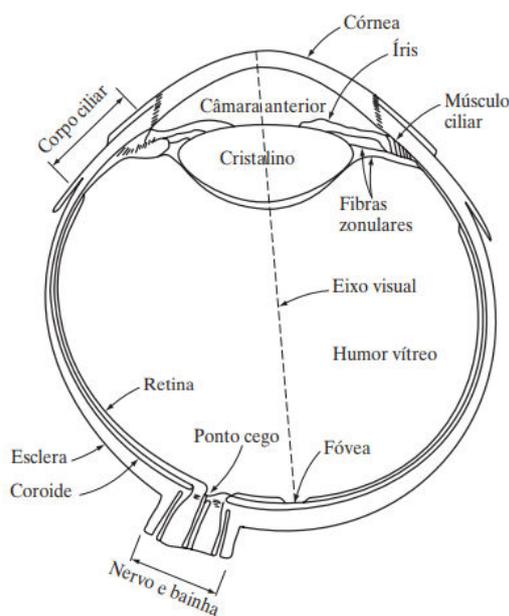
Como definido acima uma imagem digital possui um número finito de elementos em um plano e esses elementos possuem uma localização e um valor de amplitude específico. Tais elementos são chamados de elementos pictóricos, elementos de imagem, pels e pixels. Pixel é o termo mais utilizado, sendo acrônimo para *Picture element* ou elemento de imagem (BALLARD; BROWN, 1982; GONZALES; WOODS, 2009).

### 2.5.1 - Elementos da percepção visual

Embora o processamento de imagens digitais se baseie em modelos matemáticos e probabilísticos, para a escolha de uma técnica para determinado critério visual é necessário à intuição e análise humana. Para isso o primeiro passo é a compreensão básica do funcionamento da visão humana, em particular a mecânica, da formação e percepção de

imagens pelo ser humano (Figura 11), correlacionando a forma que os humanos e os dispositivos de criação de imagens se comparam em termos de resolução e a capacidade de se adaptar a mudanças (GONZALES; WOODS, 2009).

**Figura 11** – Diagrama simplificado de um corte transversal do olho humano.



**Fonte: Gonzales e Wood (2009).**

O processo da visão humana é dividido em alguns processos básicos, o órgão responsável pelo sentido da visão humana é o olho, quando a luz é refletida em um objeto essa luz passa pela córnea e a pupila que são estruturas que regulam as entradas em nossos olhos pela variação de seu diâmetro, em seguida a luz passa pelo cristalino, que é uma estrutura que funciona como uma lente biconvexa que focaliza a luz em nossa retina, a retina é uma camada de tecido nervoso que fica no fundo de nossos olhos constituída por 2 tipos de fotorreceptores denominados por cones sensíveis a cores e bastonetes, sendo assim a retina é responsável pela formação da imagem e transmite essas informações na forma de impulsos nervosos ao sistema nervoso central (GONZALES; WOODS, 2009).

O número de cones em cada olho varia entre 6 a 7 milhões, e são altamente sensíveis a cores, sendo divididos em três categorias, os cones responsáveis pela recepção das cores verde, azul e vermelho. A visão fornecida pelos cones é denominada visão fotópica ou visão de luz clara (GONZALEZ; WOODS, 2009).

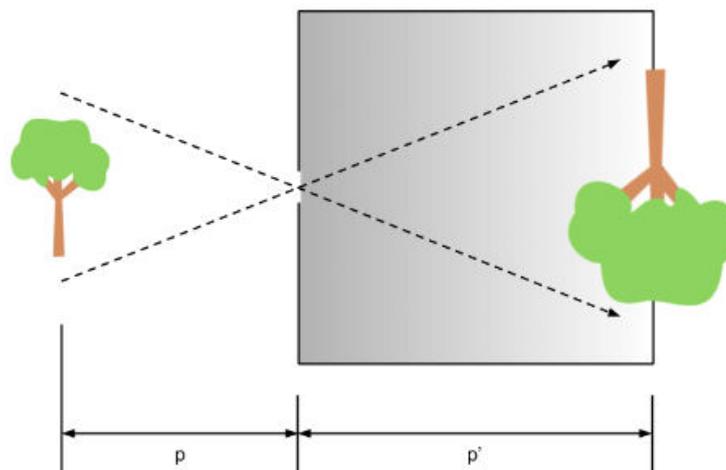
Os bastonetes tem um numero muito superior com certa de 75 a 150 milhões e todos são conectados a uma única fibra nervosa, os bastonetes são responsáveis pelo campo de visão

de uma forma geral e sua visão é denominada escotópica ou visão de luz escura (GONZALEZ; WOODS, 2009).

### 2.5.2 - Formação de imagem

Em dispositivos fotográficos, a lente tem uma distância local fixa e para focar um objeto dependendo de sua distância é necessário aumentar ou diminuir a distância da lente e o plano-imagem onde se encontra o chip de captura de imagem de uma câmera digital (Figura 12). Esses sensores sensíveis à luz atuam transformando a luz obtida de forma analógica em dados digitais: Bits e Bytes que serão processados e armazenados em forma de arquivo digital (GONZALES; WOODS, 2009; BARELLI, 2018).

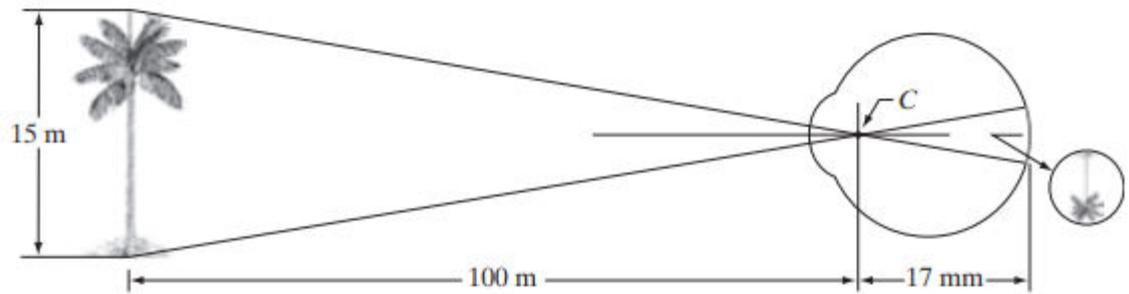
**Figura 12** – Esquema de captura de imagem feito por uma câmera escura



**Fonte: Fonte: Barelli (2018).**

Já no olho humano acontece o contrário (Figura 13), a distância entre a lente (cristalino) e o plano-imagem (retina) é fixa e para a imagem ser focalizada adequadamente é necessário uma variação no formato do cristalino por fibras zonulares que o achatam ou espessam que pode ser comparado a uma lente flexível para nitidez de objetos pertos e distantes (GONZALES; WOODS, 2009).

**Figura 13** – Representação gráfica do olho humano focalizando um objeto. O ponto “C” é o centro óptico do cristalino.

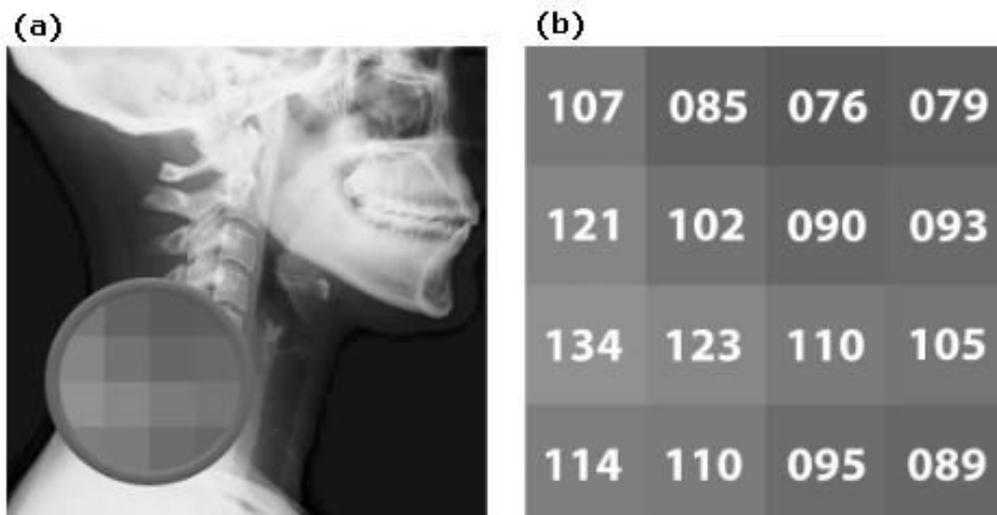


Fonte: Gonzales e Woods (2009).

### 2.5.3 - Representação de imagem digital

Segundo Gonzales e Woods (2009) a forma como um computador consegue “enxergar” uma imagem é através de uma função bidimensional,  $f(x,y)$  em que sua amplitude é o valor de um pixel. Deste modo pode-se pensar em uma matriz de  $m \times n$  em que cada intersecção das coordenadas  $m_x$  e  $n_y$  é um pixel e tem um valor de luminosidade (Figura 14).

**Figura 14** – Imagem digital de uma Radiografia Cefalométrica Lateral: (a) detalhe da radiografia com área de pixels destacada; (b) Representação matricial da área selecionada e seus níveis de cinza correspondentes.



Fonte: Barelli (2018).

## 2.6 - Inteligência artificial

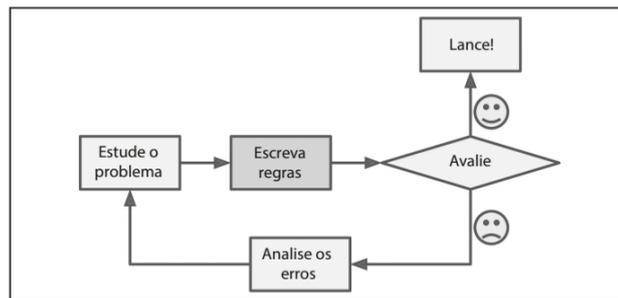
Segundo Haykin (2001) o objetivo da inteligência artificial consiste em desenvolver paradigmas ou algoritmos que necessitem de uma máquina com alto processamento para realizar tarefas cognitivas, em que os humanos são atualmente os melhores. Para tala inteligência artificial deve ser capaz de realizar três coisas: armazenar o conhecimento, aplicar esse conhecimento para a resolução de um problema definido e adquirir conhecimento através dessa experiência. Um sistema de inteligência artificial possui três componentes básicos: representação, que é o componente responsável pela comunicação homem-máquina; raciocínio, que atua na forma ou habilidade de resolver problemas; e, aprendizagem, na qual através das informações obtidas do ambiente são transformadas em uma base de conhecimento e permitem que a máquina consiga revisar ou avaliar a hipótese de resolução.

Das subáreas que compõe a Inteligência Artificial (IA) é o aprendizado de máquina que tem o objetivo de extração de padrões complexos de uma grande quantidade de dados (VELÁSQUEZ et al., 2020).

### 2.6.1 - Treinamento ou aprendizado de máquina (*machine learning*)

O aprendizado de máquina pode ser definido como a ciência da programação de computadores, para que eles possam através dos dados aprenderem ou também como o campo de estudo que dá habilidades a um computador de aprender sem que seja explicitamente programado conforme a abordagem tradicional (Figura 15), onde teremos que programar cada regra para a resolução de um problema. A aprendizagem de máquina tem duas formas diferentes de como se é processado a informação: o indutivo, em que se utilizam padrões gerais e regras determinadas a partir de dados brutos e da experiência já adquirida, em contra partida temos o processamento dedutivo onde utilizamos regras gerais para determinar fatos específicos (HAYKIN, 2001; GERÓN, 2019).

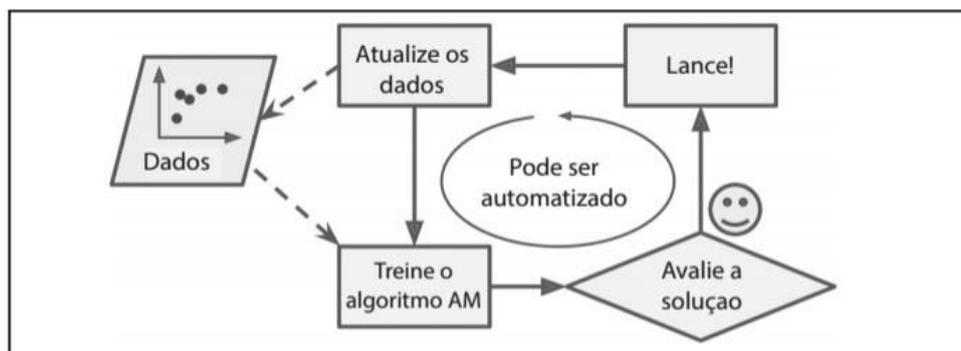
**Figura 15** – Sistema genérico baseado na abordagem tradicional de programação, onde todos os passos do algoritmo são previamente programados.



Fonte:Gerón (2019).

Na abordagem tradicional quando tem-se que resolver um problema que não é trivial, ou seja, que não se conhece todos os tipos de validação, há necessidade de se criar uma longa lista de regras complexas para conseguir chegar ao objetivo, tornando a manutenção desse programa difícil e engessada para novas regras que podem surgir na avaliação da resolução do problema em contra partida utilizando técnicas de aprendizado de máquina, a partir dos dados, podemos criar um modelo matemático para aprender a resolução do problema e ir evoluindo de acordo com o que o ambiente proporciona mais dados (Figura 16), e se destacando assim em problemas complexos para abordagens tradicionais substituindo soluções já existentes que exigem muitas configurações manuais, flexibilidade para se adaptar a novos dados e uma melhor compreensão de problemas complexos (GERÓN, 2019).

**Figura 16** - Sistema genérico baseado em aprendizado de máquina, Onde não se programa regras para resolução do problema utilizando os dados para treinamento de uma inteligência artificial.



Fonte:Gerón (2019).

## 2.6.2 -Tipos de aprendizado de máquina

Segundo Gerón (2019), existem diversos tipos de sistemas de aprendizados de máquina, os quais podem ser divididos em três critérios: supervisionados; forma de aprendizagem; e comparativo. Os critérios podem ser divididos em subcategorias, sendo que esses critérios não são exclusivos dessa forma, há possibilidade de combiná-los para melhorar a rede neural.

Nos supervisionados temos os sistemas que sofrem ou não supervisão humana:

- **Aprendizado Supervisionado** – nesse modelo, os dados de treinamento são fornecido junto com a saída esperada, assim a rede sabe se o resultado está certo ou errado e faz o ajuste para tentar diminuir esses erro, esse tipo de aprendizagem é mais utilizado em redes para classificação, os algoritmos que são mais comumente usados com esse tipo de treinamento são: **k-Nearest Neighbours, regressão linear, regressão logística, máquinas de vetores de suporte, árvores de decisão e Redes neurais;**
- **Aprendizado não supervisionado** – nesse tipo de treinamento não se tem a resposta correta ou rótulos previamente definidos, onde a partir dos dados o algoritmo consegue fazer a divisão de grupos semelhantes, e com isso obtemos informações sobre os grupos, como quantidade, frequência. São muito utilizados para se encontrar informações de nicho de negócio, por exemplo divisão de visitantes do site por horário, idade e sexo, algoritmos comumente usados com esse tipo de treinamento são: **Clustering, visualização e redução da dimensionalidade e aprendizado da regra de associação;**
- **Aprendizado supervisionado** – alguns dados de treinamento estarão parcialmente rotulados, uma grande parte não estará rotulada e outra parte estará completamente rotulada, onde esse algoritmo vai separar os dados em classes ou objetos semelhantes e após isso ele aguarda por rótulos nas classes. Utilizando tanto a parte de algoritmos supervisionados e não supervisionados, por exemplo o Google fotos, ele identifica todos os objetos e pessoas de suas fotos e a partir do momento que você marca uma pessoa em uma foto esse rótulo é utilizado nas demais fotos sem que você precise fazer aquela marcação
- **Aprendizado por reforço** – Nesse método de treinamento o sistema de aprendizado é chamado de agente, onde ele vai observar o ambiente, selecionar e executar ações e ganhar recompensas ou penalidade, dessa forma o algoritmo

vai aprender sozinho qual a melhor estratégia ou política para obter o maior número de recompensas. Esse tipo de algoritmo é muito utilizado em robôs no processo para aprender a andar ou seja toda vez que ele tomar uma ação e cair o algoritmo sofre uma penalidade atualizando a sua política de escolhas.

Aprendizado on-line ou em lote é um outro critério utilizado para classificar se o sistema vai aprender de forma incremental ou seja a cada vez que ele é utilizado os dados são agregados em sua base de conhecimento ou recebera apenas uma carga de dados para treinamento:

- **Aprendizado em lote** – dessa forma o sistema não é capaz de aprender de forma incremental ou seja a cada iteração de novos dados, com isso temos uma demanda de muito esforço computacional e tempo para treinar o modelo;
- **Aprendizado on-line** – dessa forma o sistema aprende de forma incremental sendo alimentado e treinado como cada iteração do sistema, cada etapa do aprendizado se torna mais rápida e barata dando assim flexibilidade ao seu sistema para aprender novas regras, por exemplo, em um sistema de Spam precisa reconhecer as palavras chave de forma rápida à medida que os “golpistas” mudam a forma de envio de e-mail.

Outra forma de se categorizar são os aprendizados baseado em instância e aprendizado baseado em modelo, esse tipo de categoria se refere à capacidade da máquina generalizar um problema:

- **Aprendizado baseado em instância** – esse tipo consiste em aprendizado de regras por meio de memorização e em seguida tenta generalizar para novos casos utilizando uma medida de similaridade que pode ser básica, como numero de caracteres em um texto ou numero de pixels em uma foto;
- **Aprendizado baseado em modelo** – esse tipo de aprendizado utiliza um conjunto de exemplos para a construção de um modelo que seja capaz de fazer previsões a partir de um modelo matemático.

## 2.7 - Redes Neurais artificiais

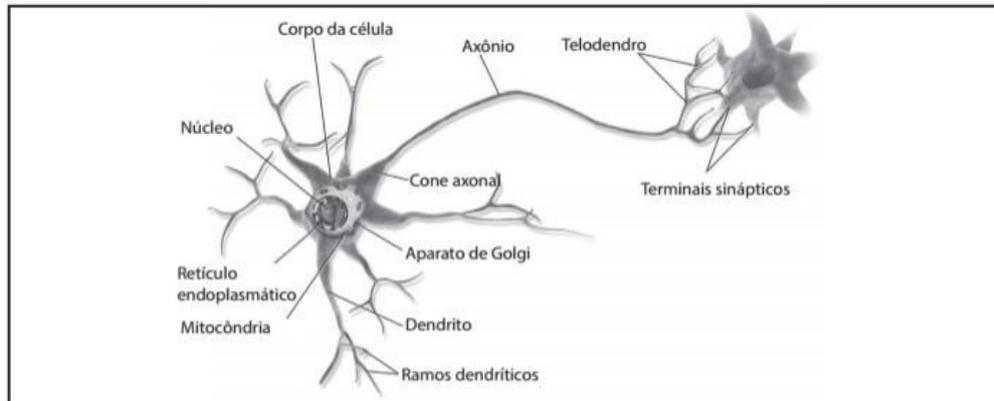
O uso de redes neurais artificiais (RNA) tem sido fomentado, pois possui similaridade com o cérebro humano, que processa informações de uma forma diferente a um computador digital convencional. A rede neural é um processador paralelamente distribuído que contém unidades de processamento simples e se assemelham ao cérebro humano em dois aspectos, sendo eles, a capacidade de adquirir conhecimento a partir de seu ambiente através de um processo de aprendizagem e as forças de conexão entre neurônios, conhecidos como pesos sinápticos tais são utilizados para armazenar o conhecimento adquirido gerando benefícios como não-linearidade, generalização, resposta a evidências no contexto de classificação de padrões e tolerância a falhas (HAYKIN, 2001).

O uso de Redes Neurais Artificiais está relacionado ao aprendizado de máquina (*Machine Learning*) e o uso de camadas de neurônios artificiais é chamado de aprendizagem profunda (*Deep Learning*) que tenta imitar a atividade de neurônios existentes no cérebro humano (VELÁSQUEZ et al., 2020).

### 2.7.1 - O Neurônio biológico

A principal célula de nosso sistema cognitivo é o neurônio (Figura 17), seu funcionamento é basicamente a condução de impulsos elétricos através de reações químicas chamadas de sinapses, fazendo uma comparação entre o neurônio e uma porta lógica de silício, os eventos em um circuito de silício acontecem na ordem de nano segundos ( $10^{-9}$ s) enquanto eventos neurais acontecem na ordem de milissegundos ( $10^{-3}$ s) entretanto estima-se que existem aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões químicas entre eles. O neurônio é composto de um corpo celular que contém um núcleo e várias ramificações que se chamam dendritos, além de uma extensão chamada axônio que se subdividem em teledendros, e na extremidade dos teledendros existem os terminais sinápticos que estão conectados quimicamente aos dendritos de outro neurônio, assim o neurônio recebe impulsos elétricos de outros neurônios através das sinapses que pode em alguns milissegundos impor ao neurônio receptivo um estado de excitação onde ele irá produzir seu próprio impulso elétrico ou inibição não repassando o impulso elétrico ao próximo neurônio (HAYKIN, 2001; GERÓN, 2019).

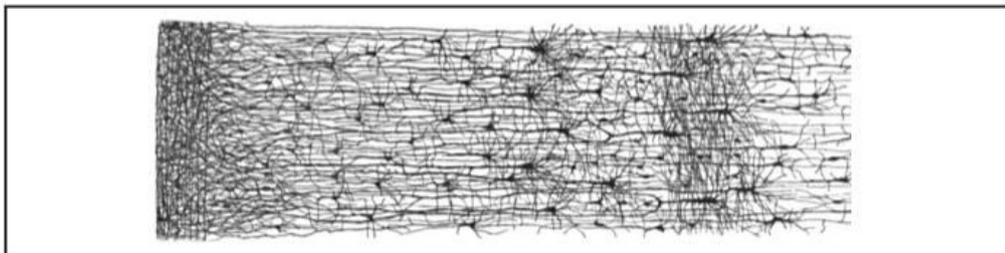
**Figura 17** - Neurônio Biológico.



Fonte: Gerón (2019).

Dessa forma, os neurônios biológicos parecem se comportar de certa forma bastante simples, mas como dito anteriormente estão organizados em uma vasta rede com bilhões de neurônios a arquitetura das redes neurais biológicas (RNB) ainda hoje é um objeto de pesquisa ativa e em partes que o cérebro já foi mapeado observa-se que os neurônios estão organizados em camadas consecutivas em forma de rede (Figura 18) (GERÓN, 2019).

**Figura 18** - Múltiplas camadas em uma rede neural biológica do córtex humano.



Fonte: Gerón (2019).

### 2.7.2 - O Neurônio artificial

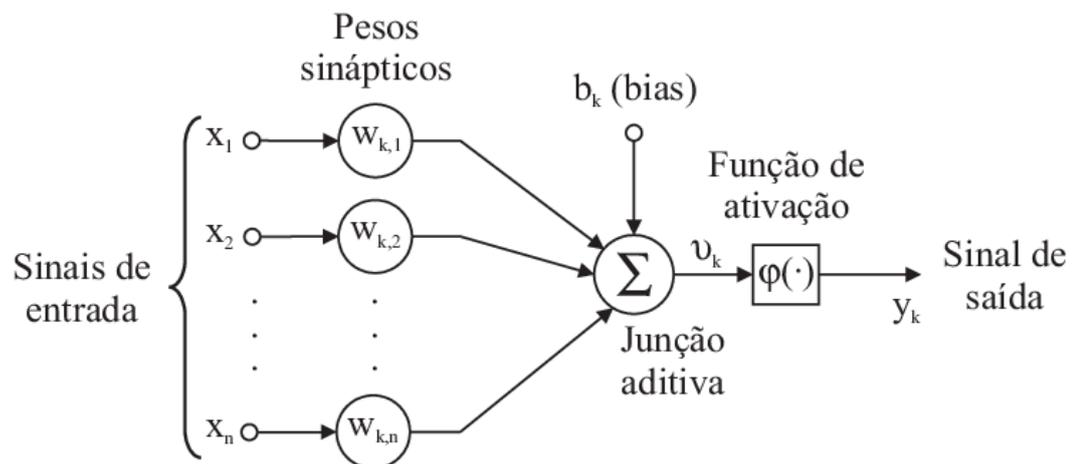
Warren McCulloch foi um psiquiatra e neuroanatomista e Walter Pitts, um prodígio matemático. Eles propuseram um modelo simples de neurônio biológico que descrevia o calculo lógico das redes neurais unificando os estudos de neurofisiologia e da lógica matemática que mais tarde ficou conhecido como neurônio artificial. O neurônio artificial trabalha da mesma forma que um neurônio biológico onde ele vai ter o estado excitatório e o inibitório que será calculado a partir de sua função de ativação (HAYKIN, 2001; GERÓN, 2019).

Os neurônios são unidades que transformam informações através de uma soma dos dados de entrada e transformam a soma ponderada através de uma função não linear de variáveis, enquanto suas conexões tem a responsabilidade de redimensionar a saída de uma camada e transmitir essa informação que será a entrada para a próxima camada de neurônios (HAHN, 2009; VELÁSQUEZ et al., 2020).

### 2.7.3 - Modelo de um neurônio

O neurônio artificial é uma unidade de processamento fundamental de uma rede neural (Figura 19). Abaixo se descreve um modelo de neurônio não-linear que é a base para a formação de uma rede neural artificial.

**Figura 19** - Modelo não linear de um neurônio.



Fonte: adaptado de Haykin (2001).

Podem ser identificados três elementos básicos desse modelo (HAYKIN, 2001):

1. Conjunto de sinapses ou elos de conexão, que tem a característica de ter um peso próprio, basicamente uma entrada  $x_j$  na entrada da sinapse é multiplicados pelo peso  $W_{kj}$ . Ao contrário de uma sinapse biológica, o peso sináptico de um neurônio artificial pode conter valores negativos e positivos (HAYKIN, 2001);
2. Uma função de soma ou junção aditiva para fazer a soma dos sinais ponderados pelos pesos (HAYKIN, 2001);
3. Uma função de ativação que restringe a amplitude da saída de um neurônio, essa função de ativação é também conhecida como função restritiva, pois restringe a amplitude de um sinal de saída a um valor finito, normalmente esse intervalo é entre os valores de 0 e 1 (HAYKIN, 2001).

Nesse modelo neural temos a presença de um bias aplicado externamente que é representado por  $b_k$ , com o efeito de aumentar ou diminuir a entrada líquida da função de ativação. Ou seja, Bias é uma constante que ajuda o modelo de uma maneira que ele possa se adaptar melhor aos dados fornecidos (HAYKIN, 2001).

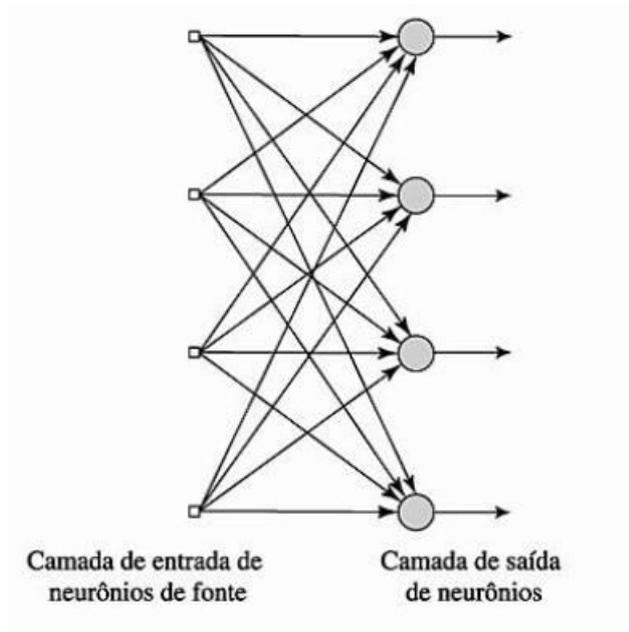
## **2.8 - Arquiteturas de redes Neurais**

Segundo Haykin (2001), a forma que os neurônios estão estruturados em uma rede neural artificial está diretamente ligada ao algoritmo de aprendizagem utilizado para treiná-la, em geral identificamos três classes de arquiteturas de redes neurais, são elas, redes de camada única onde temos uma camada de neurônios de entrada e uma camada de neurônios de saída caracterizando uma rede acíclica, redes de múltiplas camadas onde existem uma ou mais camadas ocultas tornando a rede capaz de extrair estatísticas de ordem elevada e as redes recorrentes que se distinguem das demais pois possuem um laço de realimentação onde uma saída de um neurônio é realimentada para sua própria entrada.

### **2.8.1 - Rede Alimentada adiante com camada única**

Em uma rede neural de camadas, os neurônios são divididos por camadas, a forma mais simples que existe dessa arquitetura é a rede de camada única (Figura 20), temos apenas a camada de entrada de nós/neurônios de fonte que estão ligados à camada de saída de neurônios ou nós computacionais dessa forma essa rede possui apenas a alimentação adiante ou *feedforward*, pois os dados se movimentam apenas da camada de entrada para a camada de saída (HAYKIN, 2001).

**Figura 20** - Rede *Feedforward* ou acíclica com camada única de neurônios

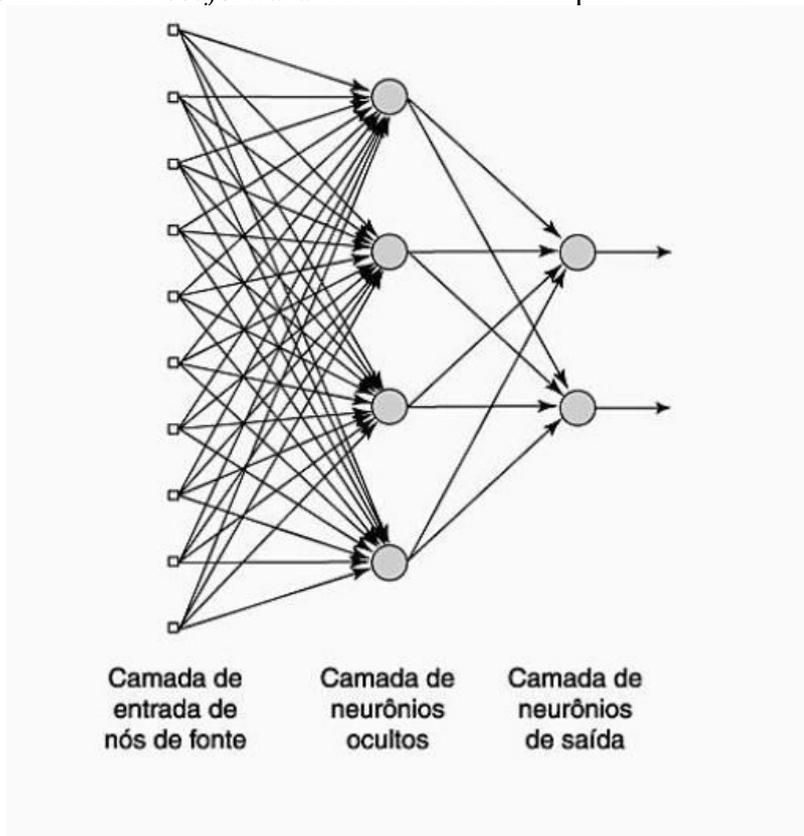


Fonte:Haykin (2001).

### 2.8.2 - Redes Alimentadas adiante com múltiplas camadas

Essa arquitetura de rede se difere da primeira arquitetura apresentada anteriormente na quantidade de camadas (Figura 21), pois possui uma ou mais camadas ocultas, os neurônios/nós computacionais tem a função de dirigir os dados de entrada para a saída de maneira mais útil, com isso conseguimos extrair estatísticas de ordem elevada, dessa forma a rede neural adquire uma perspectiva global. Essa arquitetura é muito valiosa quando o tamanho da entrada de dados é grande e as camadas ocultas conseguem distribuir melhor os dados sem que a rede se sobrecarregue.

**Figura 21** - Rede *Feedforward* ou acíclica de múltiplas camadas.

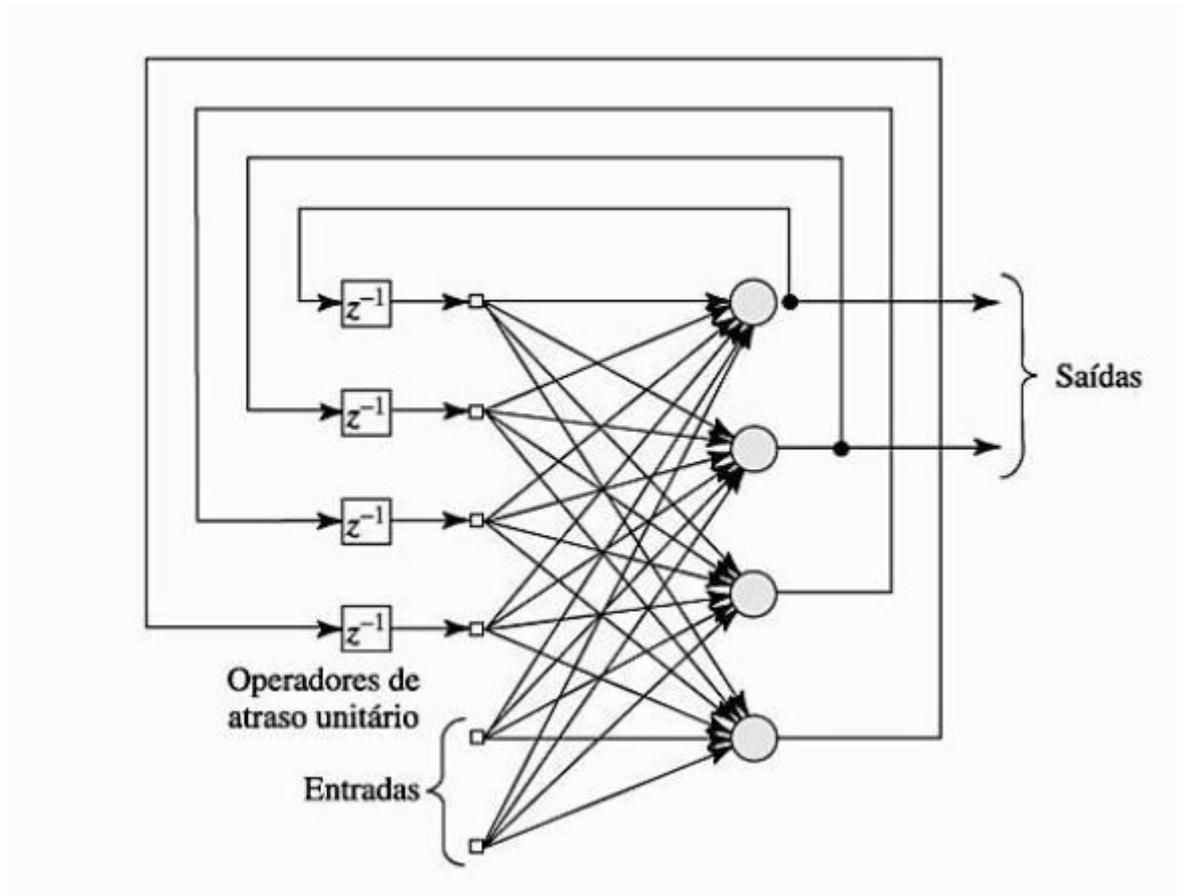


Fonte: Haykin (2001).

### 2.8.3 - Redes recorrentes

Uma rede neural recorrente se distingue das demais redes, pois possui pelo menos um laço de realimentação (Figura 22), ou seja, a saída de um neurônio alimenta outro neurônio da mesma camada, essa realimentação possui um profundo impacto na capacidade de aprendizagem da rede e no seu desempenho, além disso, ela possui um elemento a mais que se chama atraso unitário (representado por  $z^{-1}$ ), resultando em um comportamento não linear ampliando a capacidade da rede (RAIKIN, 2001).

Figura 22 - Rede recorrente com neurônios ocultos.

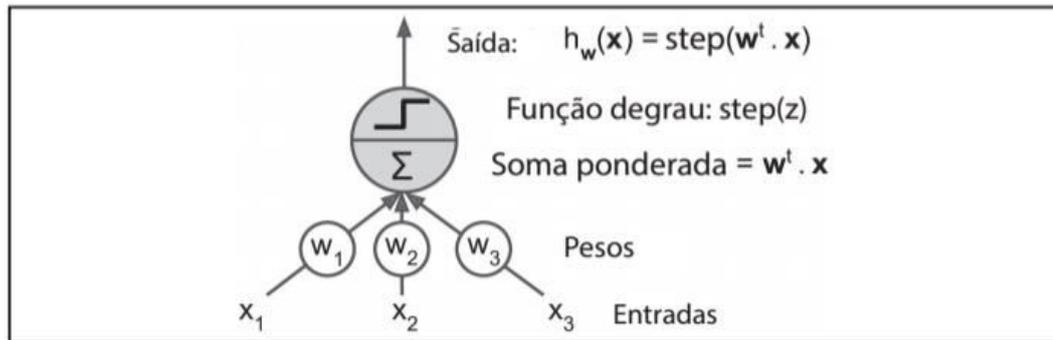


Fonte: Haykin (2001).

## 2.9 - Perceptron

Idealizado em 1957 por Frank Rosenblatt, o perceptron é uma das arquiteturas mais simples para redes neurais artificiais pertencentes ao grupo de *feedforward*, ou seja, alimentação para frente. Ela é baseada em um tipo de neurônio chamado de *unidade linear com threshold* (LTU em inglês), suas entradas e saídas são números em vez de valores binários e cada conexão de entrada está associada a um peso sináptico. A LTU faz o cálculo da soma ponderada de suas entradas  $z = w_1x_1 + w_2x_2 \dots + w_nx_n = w^t \cdot x$  aplicando uma função degrau e esta exibe o resultado  $h_w(x) = \text{step}(z) = \text{Step}(w^t \cdot x)$  (Figura 23) (GERÓN, 2019).

**Figura 23** - Unidade linear com *Threshold*.



Fonte: Gerón (2019).

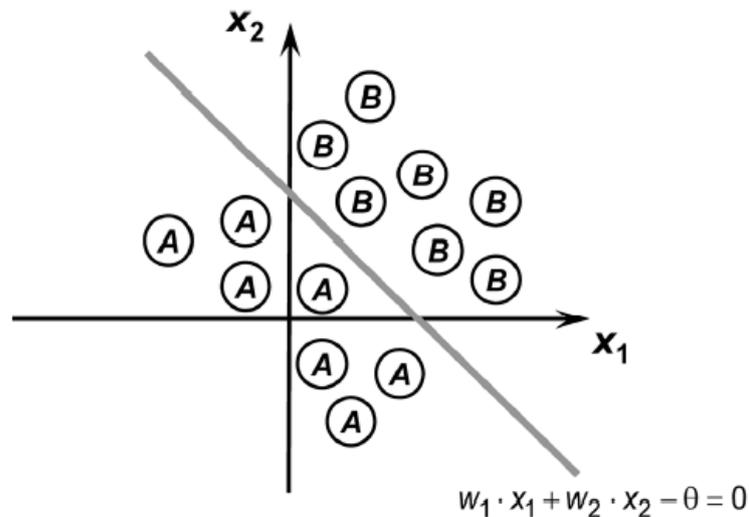
A função degrau mais comum em *perceptrons* é a função Heaviside e também utilizado as vezes a função sinal (GERÓN, 2019).

$$\text{Heaviside}(z) = \begin{cases} 0 & \text{se } z < 0 \\ 1 & \text{se } z \geq 0 \end{cases} \quad (1)$$

$$\text{sinal}(z) = \begin{cases} -1 & \text{se } z < 0 \\ 0 & \text{se } z = 0 \\ +1 & \text{se } z > 0 \end{cases} \quad (2)$$

Aprendizado supervisionado de uma rede perceptron, foi inspirado pela regra de Hebb, onde foi sugerido que quando um neurônio biológico desencadeia o outro neurônio com frequência, a conexão desses neurônios ficam mais forte, essa regra ficou conhecida com aprendizado Hebbiano, em suma as redes perceptrons utilizam uma variante dessa regra que leva em consideração o erro produzido pela rede não reforçando a conexões que contribuíram para a saída errada (condição inibitória). A fronteira de decisão de perceptrons é incapaz dessa forma de aprender padrões complexos. Porém se o problema puder ser separado linearmente (Figura 24), a rede perceptron consegue convergir para uma solução, o que é chamado de Teorema de convergência perceptron (SILVA; SPATTI; FLAUZINO, 2010; GERÓN, 2019).

**Figura 24** - Ilustração de fronteira de separação (Neurônio com duas entradas).



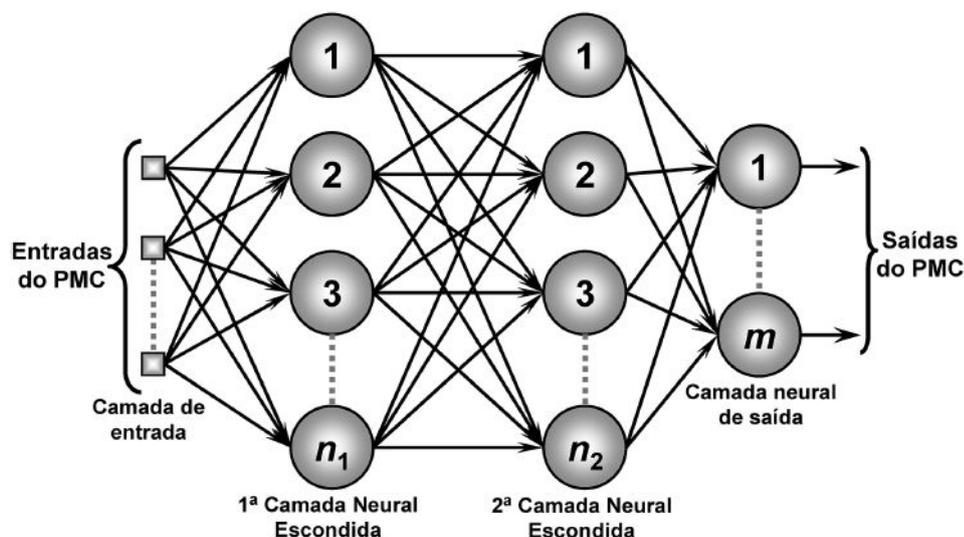
Fonte: SILVA; SPATTI; FLAUZINO, (2010).

### 2.9.1 - Perceptron multicamada e retropropagação

Algumas das limitações da rede perceptron podem ser eliminadas ao empilharmos ou concatenarmos vários perceptrons. A RNA resultante dessa junção se chamada Perceptron multi camada(PMC). Um PMC é composto de uma entrada, uma ou mais camadas LTU chamadas de camadas escondidas ou ocultas e uma camada de saída, as redes de PMC são caracterizadas pelas elevadas taxas de sucesso em diversos tipos de problemas nas mais diferentes áreas do conhecimento, sendo considerada uma das arquiteturas mais versáteis quanto a sua aplicabilidade com aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsões de séries temporais e otimização de sistemas (SILVA; SPATTI; FLAUZINO, 2010; GERÓN, 2019).

A figura 25 mostra uma PMC com a camada de entrada, duas camadas ocultas e uma camada de saída, como podemos perceber a rede neural mostra-se totalmente conectada ou seja um neurônio sempre vai estar conectada a todos os nós/neurônios da camada anterior, e conforme visto no perceptron, a PMC também é uma rede *feedforward* e seu sinal progride para a frente , da esquerda para a direita percorrendo todas as camadas(HAYKIN, 2001).

Figura 25 - Ilustração da rede Perceptron multi-camadas



Fonte: SILVA; SPATTI; FLAUZINO, (2010).

Apesar da rede PMC ser inovadora muitos pesquisadores tentaram encontrar uma forma de se treinar porém sem sucesso, mas a partir do fim dos anos de 80 devido a publicação do livro *Parallel Distributed Processing*, em 1986, D.E. Rumelhart *et al.* Onde foi demonstrado o algoritmo de *Backpropagation* ou retropropagação do erro foi possível melhorar o treinamento e aplicabilidade dessa rede. O algoritmo de treinamento alimenta cada instância e faz o cálculo de cada saída de todos os neurônios da rede camada por camada, podemos chamar este processo de *Forward pass* ou fazer a previsão do resultado, no final é feito a medida do erro na última camada calculando a diferença do resultado desejado com o resultado real, dessa forma o algoritmo começa a fazer o cálculo de quanto cada neurônio contribuiu para o erro da saída até chegar na camada de entrada *reverse pass* ou retropropagação e por fim é feito o ajuste de todos os pesos da rede para tentar reduzir o erro na próxima iteração ou época (SILVA; SPATTI; FLAUZINO, 2010; GERÓN, 2019).

### 3 - MATERIAL & MÉTODOS

#### 3.1 - Linguagem de programação

A linguagem de programação escolhida para o desenvolvimento do projeto foi o Python, por ser uma linguagem de código aberto e livre, de modo que o usuário tem quatro liberdades essenciais:

- A liberdade de executar o programa como quiser, para qualquer propósito (liberdade 0).
- A liberdade de estudar como o programa funciona, e alterá-lo de forma que ele faça sua computação como você deseja (liberdade 1). Acesso ao código-fonte é uma pré-condição para isso.
- A liberdade de redistribuir cópias e assim você pode ajudar outros (liberdade 2).
- A liberdade de distribuir cópias de suas versões modificadas para outros (liberdade 3). Ao fazer isso, você pode dar a toda uma comunidade a chance de se beneficiar de suas alterações. Acesso ao código-fonte é uma pré-condição para isso (STALLMAN, 2013).

Além das características citadas acima também possui portabilidade, podendo ser desenvolvido nas principais plataformas de sistema operacional, tem integração com diversos componentes de outras linguagens podendo ser utilizado como uma extensão ou API. O Python também fornece muitas bibliotecas de suporte como *opencv* para manipulação e processamento de imagem, *numpy* para manipulação de vetores e matrizes e *matplotlib* ferramenta para gerar gráficos e histogramas (LUTZ; ASCHER, 2007; GERÓN, 2019).

### 3.2 - Aquisição de imagens

Foram coletadas 246 folhas de eucalipto na Universidade Federal de São Carlos, Campus Lagoa do Sino, no município de Buri, São Paulo, Brasil (Lat. 23°35'50.406"S Long. 48°31'47.942"W). Desse total, 69 folhas apresentavam manchas foliares causadas por *Mycosphaerella*, 89 folhas estavam com sintomas de ferrugem (causada pelo fungo *Austropuccinia psidii*) e 88 folhas apresentavam-se sadias.

As folhas coletadas apresentavam diferentes tamanhos e níveis de severidade (baixa, média e alta) para as doenças presentes.

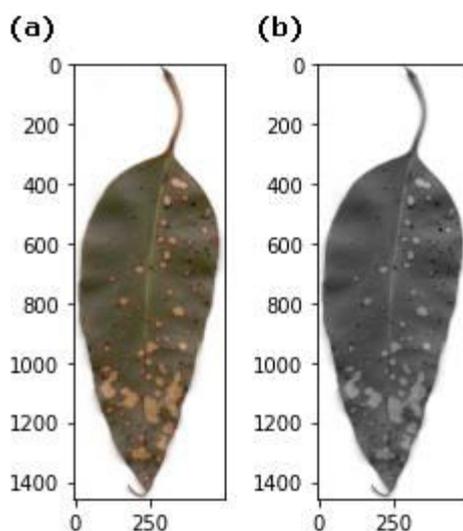
As folhas foram digitalizadas utilizando-se uma impressora multifuncional HP PSC 1510 com resolução de 300 dpi (Dots per inch ou pontos por polegada quadrada), que representa o número de pontos que são encontrados em uma polegada quadrada daquela imagem (PEDRINI; SCHWARTZ, 2008), e arquivados no formato “jpg”. Todas as imagens resultantes da etapa de digitalização atenderam as necessidades de tamanho, resolução, nitidez para elaboração da rede neural.

### 3.3 - Processamento das imagens

A Segmentação de objetos é a etapa mais importante no pré-processamento de imagens, uma vez que permite separar o objeto de interesse em uma nova imagem para diminuir os ruídos ou qualquer irregularidade presente na imagem original, separando apenas as características de interesse. O objeto a ser estudado é considerado o primeiro plano e os pixels que não fazem parte do objeto são considerados segundo plano. A segmentação é essencial para se possa extrair apenas as características desejadas do objeto com o objetivo de obter informações e detalhes para poder classificá-lo futuramente (BARELLI, 2018; KIRUTHIKA et. al., 2019).

As imagens foram processadas utilizando-se a biblioteca OpenCV no Python, fazendo a leitura da imagem original com a função *imread()* e transformando-a em tons de cinza para ser aplicado o processo de limiarização ( conforme podemos ver na Figura 26).

**Figura 26** – Imagem das folhas de eucalipto nas etapas de pré e pós-processamento: (a) imagem original de uma folha de eucalipto com manchas foliares causadas por *Mycosphaerella*; (b) saída da função *imread()* em tons de cinza a direita.



Fonte: Autor

#### 3.3.1 – Segmentação por binarização

A segmentação por binarização, também conhecida como aplicação de limiar de intensidade, separa o objeto de interesse por meio de uma definição de valor limiar e todo pixel com valor superior a esse limiar é identificado como parte do objeto de interesse sendo redefinidos para a cor preta ou branca resultando em uma imagem binária. Para aplicar esse

processo foi utilizada a função *threshold* da biblioteca OpenCV, a qual possui 4 parâmetros obrigatórios: a imagem em tons de cinza realizado na etapa anterior; o valor de limiar, geralmente obtido de forma empírica por tentativa e erro; definição do valor da intensidade que receberá os pixels de interesse; e, método de binarização (Tabela 1) (BARELLI, 2018).

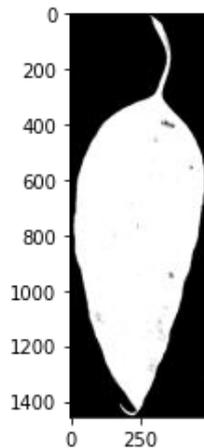
**Tabela 1** - Tabela de parâmetros de binarização

| Parâmetro         | Descrição                         |
|-------------------|-----------------------------------|
| THRESH_BINARY     | Objeto de interesse da cor preta  |
| THRESH_BINARY_INV | Objeto de interesse da cor branca |

Fonte: adaptado de Barelli (2018).

Como dito anteriormente o uso da binarização tem que ser definido por tentativa e erro, o que pode ser um grande problema, dado que ele pode ter que ser alterado dependendo da imagem a ser tratada, para a correção desse problema. Foi utilizado um método que define automaticamente esse limiar, denominado de binarização de Nobuyuki Otsu. Esse algoritmo pode ser usando em conjunto à função *threshold*, utilizando a constante THRESH\_OTSU somada ao método de binarização (Figura 27) (BARELLI, 2018).

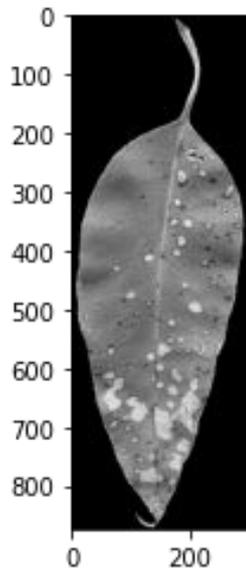
**Figura 27** - Imagem binarizada da folha de eucalipto utilizando o parâmetro THRESH\_BINARY\_INV + THRESH\_OTSU



Fonte: Autor

Ao aplicarmos imagem binarizada na imagem em tons de cinza utilizando a função *bitwise\_and ()* do OpenCV, obtém-se uma imagem processada para utilização na rede neural (Figura 28).

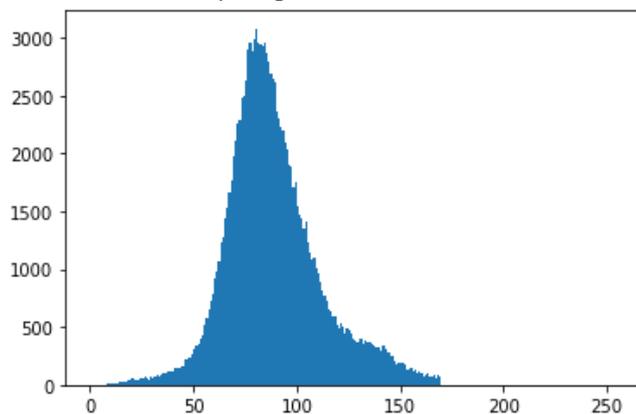
**Figura 28** – Imagem de folha de eucalipto processada pelo método de limiar por binarização.



**Fonte: Autor**

Posteriormente gera-se o histograma das imagens com auxílio da biblioteca Matplotlib, excluindo a cor/intensidade 0 (Preto) , utilizando apenas os tons de cinza do objeto de interesse como sinais de entrada para a rede neural (Figura 29).

**Figura 29** - Histograma plotado com a biblioteca matplotlib utilizando as frequências de cinza de uma folha com sintomas de *Mycosphaerella* excluindo a intensidade (0) cor preta



**Fonte: Autor**

### 3.4 – Planejamento e desenvolvimento da rede neural

A rede neural artificial foi desenvolvida na linguagem de programação Python com auxílio da biblioteca *OpenCV* para a manipulação de imagens, *matplotlib* para plotagem de

gráficos e histogramas, *Numpy* para utilização de vetores compatíveis com a arquitetura da rede neural, *Pandas* para utilização de *datasets* no treinamento, *Flask* para o servidor local Web e *Sklearn* para a montagem e configuração de hiper parâmetros da rede neural.

O *training set* – conjunto de amostras aleatórias utilizados para o treinamento da RNA – foi composto por frequências de histogramas de 60% das imagens processadas. Para efetuar o *cross validation set* - conjunto de imagens para testes da rede neural foi utilizado 40% das imagens processadas conforme recomendado por Silva, Spatti e Flauzino (2010) e FAVAN (2015).

No presente trabalho foi utilizada para a classificação de doenças uma RNA do tipo MLP (Multilayer Perceptron) – Perceptron multi camadas (PMC) com algoritmo de Backpropagation. Para a correção dos pesos sinápticos de toda a rede foi utilizada na criação do sistema o algoritmo *MLPClassifier* da biblioteca *Sklearn*.

#### 3.4.1 – Normalização dos dados

Segundo Haykin(2001), para evitar a saturação de neurônios com valores altos, como as frequências de tons de cinza do histograma, com o objetivo de padronizar os dados em uma faixa de valor adequada para a modelagem do problema esse pré-processamentos e chamado de normalização de dados. Será utilizado para a normalização dos dados função *StandardScaler* da biblioteca *Sklearn*, para padronizar os recursos removendo a média e escalonando para a variância da unidade dada pela função:

$$Z = (x-u)/s \quad (3)$$

Em que  $u$  é a média das amostras de treinamento e  $s$  é o desvio padrão das amostras de treinamento. A padronização de um conjunto de dados é um requisito comum para muitos estimadores de aprendizado de máquina, eles podem não ter o comportamento esperado se o conjunto de dados não se parecerem com os dados normalmente distribuídos.

#### 3.4.2 - Topologias da Rede Neural Artificial

A partir da topologia de rede utilizada por FAVAN (2015), em que foram utilizadas 3 camadas de redes neurais (camada de entrada, camada oculta ou escondida e camada de saída) para a discriminação de duas doenças do eucalipto (*Cylindrocladium spp.* e *bacteriose*) contendo uma taxa de aprendizagem de 0,5 precisão do problema de 0,00001 e o momentum configurado a 0,3 e a camada oculta contendo 256 neurônios, serão desenvolvidas mais 2

topologias adicionando duas camadas ocultas e 3 camadas ocultas a fim de verificar o impacto de mais camadas nas principais métricas para cada método.

A quantidade de neurônios na camada de saída foi definida como três neurônios, pois este número compreende as três classes desse estudo: folhas saudáveis, *Mycosphaerella* e ferrugem.

A quantidade de neurônios na camada de entrada serão 255, compatível com os dados de entrada que representam valores dos tons de cinza gerados a partir dos *pixels* das imagens processadas e transformadas em histograma que compreendem o valor entre 1 e 255 sendo 1 para o cinza mais escuro e 255 correspondente a cor branca, para o presente estudo descartaremos a frequência de cor 0 (preta), pois essa cor não faz parte do objeto de interesse.

As RNAs contarão com até duas camadas escondidas ou ocultas, o número de neurônios em cada camada é uma questão empírica, não existindo regras explícitas para um cálculo ideal, para o cálculo das camadas serão utilizados as abordagens de HEATON(2008) e FAVAN(2015). Será analisado o efeito dos neurônios e camadas das RNAs a fim de escolher uma topologia ser utilizada no sistema especialista. Foram testadas 8 topologias 4 como uma camada e 4 com duas camadas (Tabela 2).

**Tabela 2** - Métodos utilizados para cálculo da(s) camadas escondidas ou ocultas para a Rede Neural Artificial com a fórmula adotada para cada topologia, quantidade de neurônios da primeira camada e segunda camada, em que  $n_1$  é o número de neurônios na camada oculta,  $n$  é o número de neurônios na camada de entrada e  $n_c$  é o número de classes ou número de neurônios da camada de saída.

| Nome Método              | Fórmula   | Quantidade de neurônios na primeira camada | Quantidade de neurônios segunda camada | Codificação da topologia |
|--------------------------|---|--|--|--------------------------|
| Favan<br>(FAVAN, 2015)   | $n_1 = \left( (n_1 = 2n + 1) - \left( \frac{n_1 = n + n_c}{2} \right) + \left( \frac{n_1 = n + n_c}{2} \right) \right)$ | 256  | -                                      | Topologia 1              |
| Heaton<br>(HEATON, 2008) | $n_1 = \frac{(n + n_c)}{2}$   | 86   | -                                      | Topologia 2              |
| Heaton<br>(HEATON, 2008) | $n_1 = n \frac{2}{3} + n_c$   | 173  | -                                      | Topologia 3              |
| Heaton<br>(HEATON, 2008) | $n_1 = 2n - 1$  | 509  | -                                      | Topologia 4              |

|                          |   |     |      |             |
|--------------------------|---|-----|------|-------------|
| Favan<br>(FAVAN, 2015)   | $n_1 = \left( (n_1 = 2n + 1) - \left( \frac{n_1 = n + n_c}{2} \right) + \left( \frac{n_1 = n + n_c}{2} \right) \right)$ | 256 | 257  | Topologia 5 |
| Heaton<br>(HEATON, 2008) | $n_1 = \frac{(n + n_c)}{2}$   | 129 | 66   | Topologia 6 |
| Heaton<br>(HEATON, 2008) | $n_1 = n \frac{2}{3} + n_c$   | 173 | 118  | Topologia 7 |
| Heaton<br>(HEATON, 2008) | $n_1 = 2n - 1$  | 509 | 1017 | Topologia 8 |

**Fonte: Autor**

As 8 topologias foram testadas em 10 ensaios sendo que as amostras foram escolhidas aleatoriamente utilizando a função *train\_test\_split* da biblioteca Sklearn, em que o dataset – conjunto de histogramas foi dividido em 2 bases com valores aleatórios. Um conjunto com 60% dos histogramas para treinamento e 40% para testes e validação da rede. Cada uma das topologias foi avaliada quanto ao erro quadrático médio na época de convergência, porcentagem de acertos no treinamento e porcentagem de acerto no teste cego (40% dos histogramas não conhecidos pela rede).

Todas as topologias utilizaram os mesmos hiper-parâmetros, esses valores devem ser alterados conforme resultados obtidos, e de forma empírica ser atualizados em testes posteriores, no entanto, no presente trabalho foram mantidos os valores recomendados pela literatura (FAVAN, 2015; HAYKIN, 2001; SPATTI; FLAUZINO, 2010). A taxa de aprendizado foi configurada em 0,5; a precisão requerida para o problema foi de 0,000001 e o termo *momentum* foi configurado em 0,3.

### 3.5 - Testes e homologação da Rede Neural Artificial

A rede neural foi construída utilizando o algoritmo *MLPclassifier* da biblioteca *Sklearn*, que é otimizado para classificação de padrões, a rede será treinada com o conjunto de treino, 60% dos histogramas das imagens, após cada treinamento será medido sua performance, precisão, acurácia e generalização utilizando o conjunto de testes, 40% dos histogramas de imagem e dessa forma analisar qual topologia será utilizada no sistema especialista.

### 3.5.1 – Desempenho da RNA

Para avaliar o desempenho das topologias das redes neurais foram utilizados os valores de Acurácia, *precision*(precisão), *recall*(Revogação) e *F1 Score*, os quais foram extraídos de uma tabela de confusão (Tabela 3).

**Tabela 3** - Tabela de confusão Genérica

|      |          | Previsto                 |                          |
|------|----------|--------------------------|--------------------------|
|      |          | Positivo                 | Negativo                 |
| Real | Positivo | Verdadeiro Positivo (VP) | Falso Negativo (FN)      |
|      | Negativo | Falso Positivo (FP)      | Verdadeiro Negativo (VN) |

Fonte: FAVAN(2015)

#### 3.5.1.1 - Acurácia

A questão a ser respondida para essa métrica é no geral, o quão frequente o classificador da Rede Neural Artificial está correto, utilizando a fórmula abaixo onde A é a acurácia, VP é Verdadeiro positivo, VN é Verdadeiro negativo, FP é Falso positivo e FN é Falso Negativo (LEAL 2017; SHABARI SHEDTHI; SIDDAPPA; SHETTY, 2019) :

$$A = \frac{VP+VN}{VP+VN+FP+FN} \quad (4)$$

#### 3.5.1.2 - Precisão

A questão a ser respondida por essa métrica é das classificações feitas como corretas, quantos efetivamente estavam corretos, utilizando a formula abaixo onde Precisão, VP é Verdadeiro positivo e FP é Falso positivo (LEAL, 2017; ZHANG, 2020):

$$P = \frac{VP}{VP+FP} \quad (5)$$

#### 3.5.1.3 - Revogação

A questão a ser respondida com essa métrica é das classificações corretas realizadas, qual a frequência que a rede neural classifica como essa classe, utilizando a fórmula abaixo

onde R é recall , VP é Verdadeiro positivo e FN é Falso Negativo (LEAL, 2017; ZHANG, 2020):

$$R = \frac{VP}{VP+FN}$$

(6)

#### 3.5.1.4 - F1 score

O objetivo dessa métrica é combinar a precisão e o recall de modo que podemos analisar a qualidade geral do modelo (LEAL, 2017; NGUGI; ABELWAHAB; ABO-ZAHHAD, 2021), pela seguinte formula onde F1 é o F1 Score, P é a precisão e R é o Recall:

$$F1 = \frac{2PR}{P+R}$$

(7)

## 4 - RESULTADOS E DISCUSSÃO

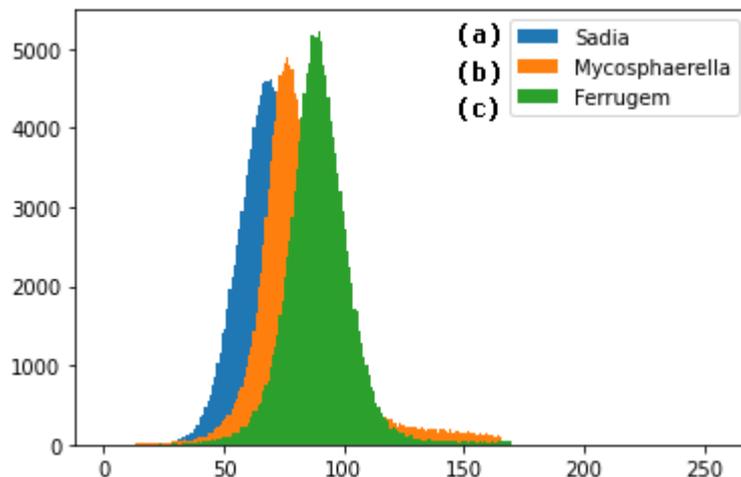
As 246 imagens foram processadas, em tons de cinza , no formato “JPG”. Para não haver discrepância entre os tamanhos as imagens foram rotacionadas para ficar na vertical, caso estivesse na horizontal, foi redimensionado para uma largura de 300 *pixels* não alterando sua proporção para não haver distorção nos dados utilizando a formula abaixo para calcular a nova altura, *NA* é a nova altura da imagem onde, *a* é a altura original da imagem, *l* é a largura original da imagem:

$$NA = 300 \frac{a}{l}$$

(8)

Na Figura 30 pode-se ver as frequências de tons de cinza do conjunto de amostras, em que tem-se as frequências plotadas de uma folha sadia, de uma folha com sintomas de *Mycosphaerella* e uma folha com sintomas de ferrugem. Com base nesses histogramas a RNA procedeu a Classificação.

**Figura 30** – Frequências de tons de cinza de folhas de eucalipto: (a) sadia em azul; (b) com sintomas de *Mycosphaerella*. em laranja; (c) com sintomas de ferrugem em verde.



Fonte: Autor

#### 4.1 – Topologia 1 – 256 Neurônios

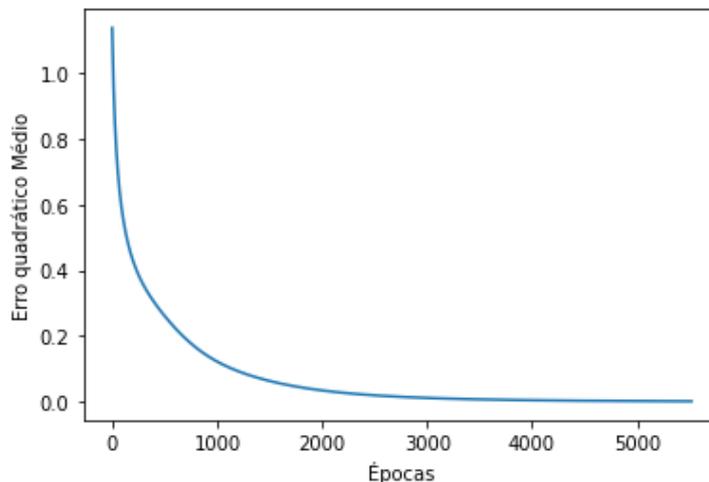
A topologia 1 foi definida com 256 neurônios para uma camada oculta utilizando o método de Favan (2015) (Tabela 4).

**Tabela 4** - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 1.

|               | Ensaio |        |        |        |        |        |        |        |        |        |
|---------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|               | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| EQM           | 0,1429 | 0,3571 | 0,0612 | 0,2143 | 0,2551 | 0,2347 | 0,2755 | 0,2551 | 0,2857 | 0,0918 |
| Épocas        | 5385   | 5356   | 5586   | 5351   | 4993   | 5376   | 5318   | 5074   | 5158   | 5518   |
| Acurácia (%)  | 94,89  | 88,77  | 96,93  | 93,87  | 92,85  | 91,83  | 90,81  | 92,85  | 89,79  | 96,93  |
| Precisão (%)  | 94,69  | 89,43  | 96,35  | 93,9   | 93,04  | 91,63  | 90,9   | 92,96  | 89,74  | 97,56  |
| Revogação (%) | 95,41  | 88,66  | 97,26  | 94,1   | 93,36  | 92,97  | 91,71  | 93,13  | 90,52  | 96,74  |
| F1 Score (%)  | 94,99  | 88,6   | 96,73  | 93,96  | 93,18  | 92,11  | 90,82  | 90,02  | 90,02  | 97,06  |

A quantidade mínima de épocas para a estabilização do erro quadrático médio (EQM) foram de duas mil épocas (Figura 31).

**Figura 31** – Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 1.



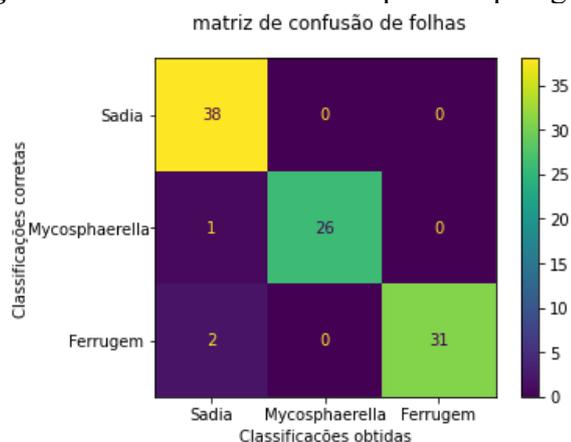
**Fonte: Autor**

Para a convergência da topologia 1, foram necessários em média 5311 épocas, com a maior quantidade no seu terceiro ensaio com 5586 épocas e a menor com 4993 no quinto ensaio. O alto número de épocas pode ser relacionado à quantidade de amostras pequena para as 3 classes utilizadas pela rede neural.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,95%, com sua melhor taxa no décimo ensaio com 96,93% e a menor no segundo ensaio com 88,77%. Outra métrica importante para avaliação da Rede Neural Artificial é o F1 Score com média de 92,74%. Com esses resultados a topologia 1, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que todas as folhas sadias foram reconhecidas corretamente pela RNA e uma imagem com *Mycosphaerella* foi classificada como sadia e 2 com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, assim com a quantidade de acertos foi bem elevado (Figura 32), gerado pela biblioteca matplotlib.

**Figura 32** – Matriz de confusão para a topologia 1.



Fonte: Autor

#### 4.2 – Topologia 2 – 86 neurônios

A topologia 2 foi definida com 86 neurônios para uma camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 5).

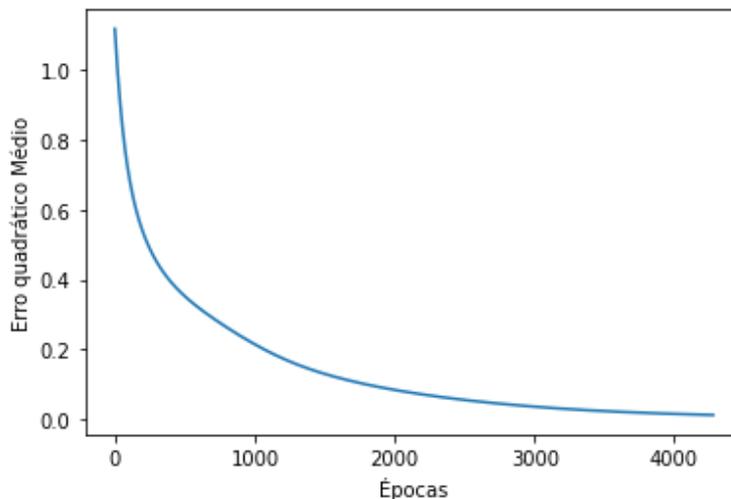
**Tabela 5** - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 2.

|                     | Ensaio |        |       |        |        |        |        |        |        |        |
|---------------------|--------|--------|-------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3     | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,1735 | 0,3163 | 0,102 | 0,1735 | 0,1735 | 0,2653 | 0,3265 | 0,2653 | 0,2551 | 0,0816 |
| <b>Épocas</b>       | 4215   | 4151   | 4279  | 4191   | 3780   | 4102   | 4074   | 3847   | 3868   | 4278   |
| <b>Acurácia(%)</b>  | 94,89  | 89,79  | 98,91 | 94,89  | 94,89  | 91,83  | 88,77  | 91,83  | 89,79  | 97,95  |
| <b>Precisão(%)</b>  | 94,99  | 90,24  | 95,48 | 94,91  | 94,97  | 91,86  | 88,42  | 91,84  | 89,4   | 98,33  |
| <b>Revogação(%)</b> | 95,41  | 89,7   | 96,3  | 95,05  | 95,27  | 92,97  | 89,12  | 92,22  | 90,47  | 97,97  |
| <b>F1 Score(%)</b>  | 95,18  | 89,67  | 95,81 | 94,97  | 95,11  | 92,26  | 88,56  | 91,98  | 89,8   | 98,1   |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio(EQM) foram de três mil e quinhentas épocas (Figura 33).

**Figura 33** – Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 2.



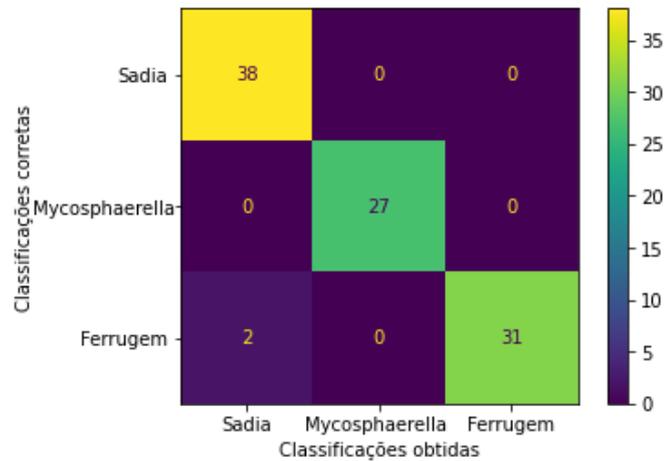
**Fonte: Autor**

Para a convergência da topologia 2, foram necessários em média 4078 épocas, com a maior quantidade no seu terceiro ensaio com 4279 épocas e a menor com 3780 no quinto ensaio. O alto número de épocas pode ser relacionado à quantidade de amostras pequena para as três classes utilizadas pela rede neural. Apesar do pequeno número de neurônios, foi a rede com melhor desempenho apenas perdendo em quantidade de épocas para a topologia 10.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 93,35%, com sua melhor taxa no terceiro ensaio com 98,91% e a menor no sétimo ensaio com 88,77%. Outra métrica importante para avaliação da Rede Neural Artificial é o F1 Score com média de 93,14%. Com esses resultados a topologia 2, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que todas as folhas saudias e com sintomas de *Mycosphaerella* foram reconhecidas corretamente pela RNA e 2 com ferrugem foram identificadas como saudias. O erro pode ter sido ocasionado pela baixa quantidade de amostras com severidade baixa, o que pode ter gerado uma quantidade de acertos bem elevado (Figura 34), gerado pela biblioteca matplotlib.

**Figura 34 - Matriz de confusão de para a topologia 2.**  
matriz de confusão de folhas



Fonte: Autor

### 4.3 – Topologia 3 – 173 neurônios

A topologia 3 foi definida com 173 neurônios para uma camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 6).

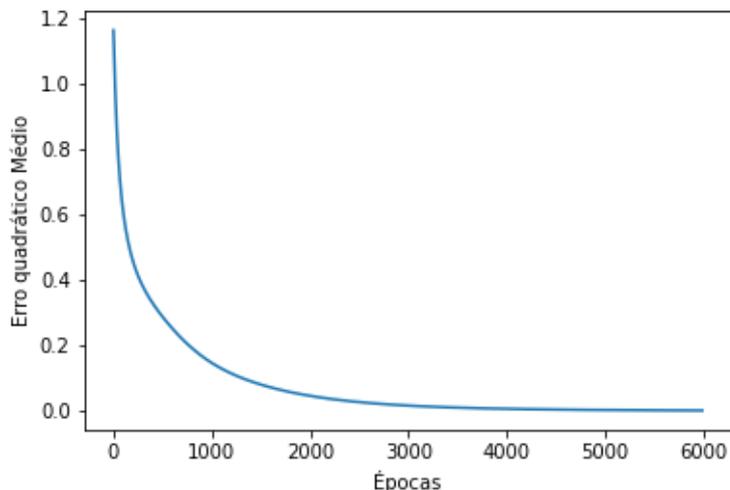
**Tabela 6 - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 3.**

|                  | Ensaio |        |        |        |        |        |        |        |        |       |
|------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|-------|
|                  | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10    |
| <b>EQM</b>       | 0,1327 | 0,3571 | 0,0918 | 0,1735 | 0,2143 | 0,3061 | 0,2857 | 0,2653 | 0,3367 | 0,816 |
| <b>Épocas</b>    | 5868   | 5603   | 5908   | 5611   | 5416   | 5631   | 5445   | 5308   | 5466   | 5991  |
| <b>Acurácia</b>  | 95,91  | 88,77  | 96,93  | 97,89  | 93,87  | 90,81  | 89,79  | 91,83  | 87,75  | 97,95 |
| <b>Precisão</b>  | 95,9   | 89,43  | 96,79  | 94,97  | 94,06  | 90,9   | 89,82  | 91,84  | 87,69  | 98,33 |
| <b>Revogação</b> | 96,42  | 88,66  | 97,26  | 95,14  | 94,26  | 91,96  | 90,56  | 92,22  | 88,71  | 97,97 |
| <b>F1 Score</b>  | 96,12  | 88,6   | 97     | 94,96  | 94,14  | 91,33  | 89,71  | 91,98  | 88     | 98,1  |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio (EQM) foram de duas mil e quinhentas épocas (Figura 35).

**Figura 35** – Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 3.



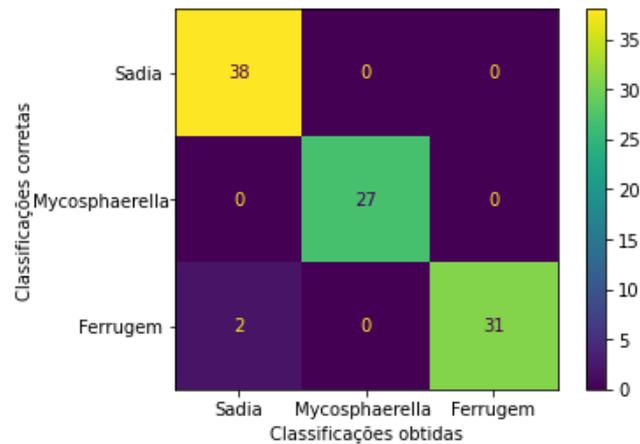
**Fonte: Autor**

Para a convergência da topologia 3, foram necessários em média 5624 épocas, com a maior quantidade no seu décimo ensaio com 5991 épocas e a menor com 5308 no oitavo ensaio. O alto número de épocas pode ser relacionado à quantidade de amostras pequena para as três classes utilizadas pela rede neural.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 93,15%, com sua melhor taxa no décimo ensaio com 97,95% e a menor no nono ensaio com 87,75%. Outra métrica importante para avaliação da Rede Neural Artificial é o F1 Score com média de 92,99%. Com esses resultados a topologia 3, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que todas as folhas sadias e *Mycosphaerella* foram reconhecidas corretamente pela RNA e duas com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 36), gerado pela biblioteca matplotlib.

**Figura 36 - Matriz de confusão de para a topologia 3.**  
matriz de confusão de folhas



Fonte: Autor

#### 4.4 – Topologia 4 – 509 neurônios

A topologia 4 foi definida com 509 neurônios para uma camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 7).

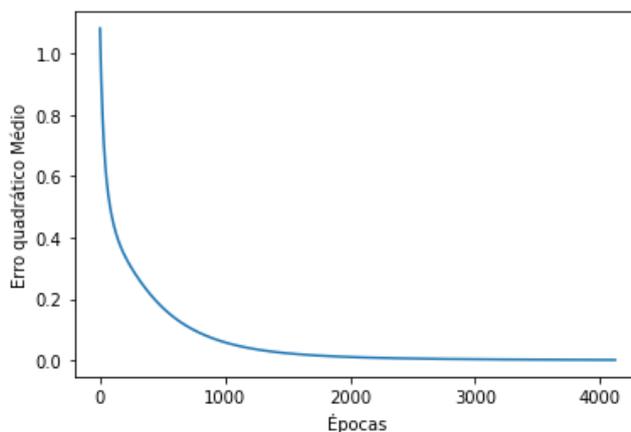
**Tabela 7 - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 4.**

|                     | Ensaio |        |        |        |        |        |        |        |        |        |
|---------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,1327 | 0,3571 | 0,0612 | 0,2653 | 0,2653 | 0,2653 | 0,2857 | 0,2653 | 0,3367 | 0,1327 |
| <b>Épocas</b>       | 4044   | 3990   | 4045   | 3962   | 3730   | 3829   | 3871   | 3690   | 3702   | 4122   |
| <b>Acurácia(%)</b>  | 95,91  | 88,77  | 96,93  | 93,87  | 91,83  | 91,83  | 89,79  | 91,83  | 87,75  | 95,91  |
| <b>Precisão(%)</b>  | 95,9   | 89,43  | 96,35  | 93,9   | 92,17  | 91,86  | 89,82  | 91,81  | 87,69  | 96,27  |
| <b>Revogação(%)</b> | 96,42  | 88     | 97,26  | 94,1   | 92,17  | 92,8   | 90,56  | 92,08  | 88,71  | 95,86  |
| <b>F1 Score(%)</b>  | 96,12  | 88,6   | 96,73  | 93,96  | 92,17  | 92,26  | 89,71  | 91,88  | 88     | 96,05  |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio (EQM) foram de mil e quinhentas épocas (Figura 37).

**Figura 37** - Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 4.



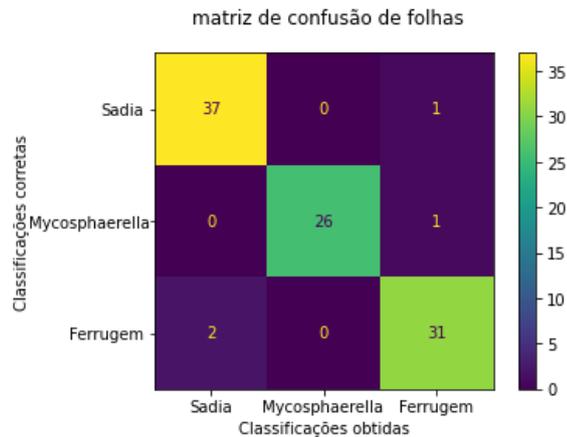
**Fonte: Autor**

Para a convergência da topologia 4, foram necessários em média 3898 épocas, com a maior quantidade no seu décimo ensaio com 4122 épocas e a menor com 3690 no oitavo ensaio. O alto número de épocas pode ser relacionado à quantidade de amostras pequena para as três classes utilizadas pela rede neural, pode-se notar que o aumento de neurônios na camada tem efeito de diminuir a quantidade de épocas para a estabilização do EQM.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,44%, com sua melhor taxa no terceiro ensaio com 96,93% e a menor no nono ensaio com 87,75%. Outra métrica importante para avaliação da Rede Neural Artificial é o F1 Score com média de 92,54%. Com esses resultados a topologia 4, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que a RNA classificou de forma incorreta uma folha sadia como uma folha com ferrugem, uma folhas com *Mycosphaerella* como uma folha com ferrugem e duas folhas com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 38), gerado pela biblioteca matplotlib.

**Figura 38 - Matriz de confusão de para a topologia 4.**



Fonte: Autor

#### 4.5 – Topologia 5 – 513 neurônios

A topologia 5 foi definida com 256 neurônios para a primeira camada oculta e 257 neurônios para a segunda camada oculta utilizando o método de Favan (2015). Os resultados da topologia 5 são apresentados na tabela 8.

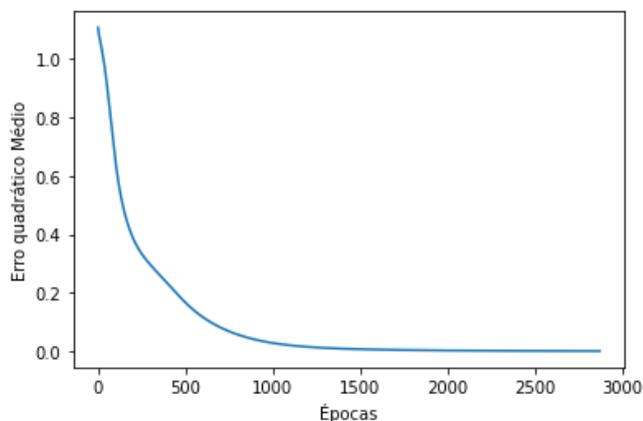
**Tabela 8 - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 5.**

|                     | Ensaio |        |        |        |        |        |        |        |        |        |
|---------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,1735 | 0,3571 | 0,0612 | 0,2143 | 0,2245 | 0,2347 | 0,8957 | 0,2551 | 0,2959 | 0,1327 |
| <b>Épocas</b>       | 2879   | 2902   | 2920   | 2914   | 2721   | 2890   | 2937   | 2742   | 2723   | 2871   |
| <b>Acurácia(%)</b>  | 94,89  | 88,77  | 96,93  | 93,87  | 92,85  | 91,83  | 89,79  | 92,85  | 88,77  | 95,91  |
| <b>Precisão(%)</b>  | 94,99  | 89,43  | 96,52  | 93,9   | 92,92  | 91,63  | 89,82  | 92,94  | 88,52  | 96,27  |
| <b>Revogação(%)</b> | 95,41  | 88,66  | 97,14  | 94,1   | 93,25  | 92,97  | 90,56  | 93,27  | 89,59  | 95,86  |
| <b>F1 Score(%)</b>  | 95,18  | 88,6   | 96,7   | 93,96  | 93,02  | 92,11  | 89,71  | 93,06  | 88,9   | 96,05  |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio(EQM) foram de mil épocas (Figura 39).

**Figura 39** - Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 5.



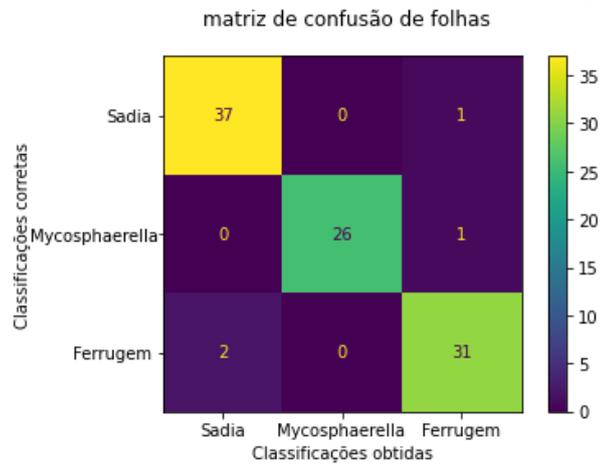
**Fonte: Autor**

Para a convergência da topologia 5, foram necessários em média 2850 épocas, com a maior quantidade no seu sétimo ensaio com 2937 épocas e a menor com 2721 no quinto ensaio. Nota-se que o número de épocas pode diminuir, a fim de estabilizar o EQM, conforme o aumento de neurônios e camadas da RNA.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,64%, com sua melhor taxa no terceiro ensaio com 96,93% e a menor no nono ensaio com 88,77%. Outra métrica importante para avaliação da Rede Neural Artificial é o F1 Score com média de 92,72%. Com esses resultados a topologia 5, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu último ensaio, mostra que a RNA classificou de forma incorreta uma folha sadia como uma folha com ferrugem, uma folhas com *Mycosphaerella* como uma folha com ferrugem e duas folhas com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 40), gerado pela biblioteca matplotlib.

**Figura 40 - Matriz de confusão de para a topologia 5.**



Fonte: Autor

#### 4.6 – Topologia 6 – 195 neurônios

A topologia 6 foi definida com 129 neurônios para a primeira camada oculta e 66 neurônios para a segunda camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 9).

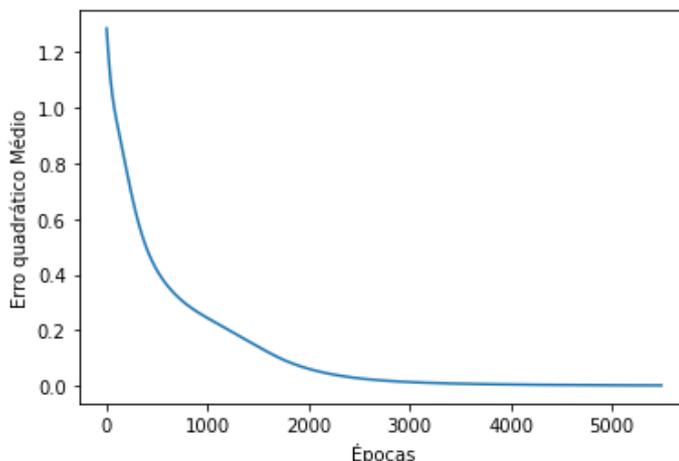
**Tabela 9 - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 6.**

|                     | ensaio |        |       |        |        |        |        |        |        |        |
|---------------------|--------|--------|-------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3     | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,2879 | 0,2857 | 0,102 | 0,2245 | 0,1735 | 0,1939 | 0,3878 | 0,2653 | 0,2347 | 0,0918 |
| <b>Épocas</b>       | 5594   | 5358   | 5272  | 5336   | 5551   | 5193   | 5236   | 5067   | 5209   | 5492   |
| <b>Acurácia(%)</b>  | 95,91  | 89,79  | 95,91 | 92,85  | 94,89  | 92,85  | 85,71  | 91,83  | 91,83  | 96,93  |
| <b>Precisão(%)</b>  | 96,27  | 90,59  | 95,48 | 92,86  | 94,97  | 92,61  | 85,34  | 91,77  | 91,82  | 97,29  |
| <b>Revogação(%)</b> | 96,27  | 89,64  | 96,3  | 93,15  | 95,27  | 93,98  | 86     | 92,22  | 92,27  | 96,74  |
| <b>F1 Score(%)</b>  | 96,27  | 89,52  | 95,81 | 92,91  | 95,11  | 93,04  | 85,47  | 91,91  | 92,03  | 96,97  |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio(EQM) foram de duas mil e quinhentas épocas (Figura 41).

**Figura 41** - Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 6.



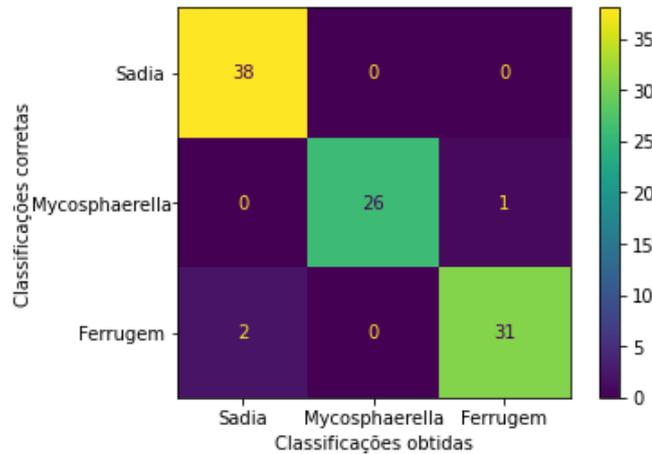
**Fonte:** Autor

Para a convergência da topologia 6, foram necessários em média 5330 épocas, com a maior quantidade no seu primeiro ensaio com 5594 épocas e a menor com 5067 no oitavo ensaio. Nota-se que o número de épocas aumentou, a fim de estabilizar o EQM, conforme a redução de neurônios da RNA mesmo possuindo 1 camada a mais do que as topologias 1,2,3 e 4.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,85%, com sua melhor taxa no décimo ensaio com 96,93% e a menor no sétimo ensaio com 85,71%. Outra métrica importante para avaliação da Rede Neural Artificial é o *F1 Score* com média de 92,90%. Com esses resultados a topologia 6, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que a RNA classificou de forma correta todas as folhas sadias, uma folha com *Mycosphaerella* como uma folha com ferrugem e duas folhas com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 42), gerado pela biblioteca matplotlib.

**Figura 42** - Matriz de confusão de para a topologia 6.  
matriz de confusão de folhas



Fonte: Autor

#### 4.7 – Topologia 7 – 291 neurônios

A topologia 7 foi definida com 173 neurônios para a primeira camada oculta e 118 neurônios para a segunda camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 10).

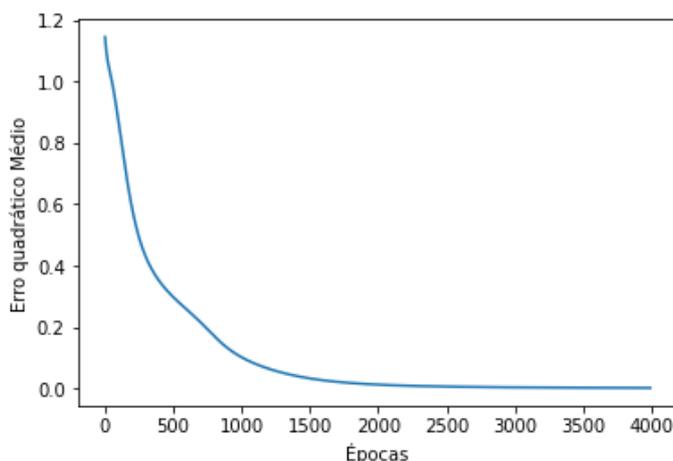
**Tabela 10** - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 7.

|                     | Ensaio |        |        |        |        |        |        |        |        |        |
|---------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,1837 | 0,3571 | 0,0612 | 0,2143 | 0,2143 | 0,2347 | 0,2959 | 0,2653 | 0,2449 | 0,0816 |
| <b>Épocas</b>       | 4016   | 3943   | 3784   | 3907   | 3779   | 3754   | 3759   | 3668   | 3671   | 3992   |
| <b>Acurácia(%)</b>  | 93,87  | 88,77  | 96,93  | 93,87  | 93,87  | 91,83  | 88,77  | 91,83  | 90,81  | 97,95  |
| <b>Precisão(%)</b>  | 93,78  | 89,43  | 96,52  | 93,9   | 94,06  | 91,63  | 88,77  | 91,84  | 90,69  | 98,33  |
| <b>Revogação(%)</b> | 94,4   | 88     | 97,14  | 94,1   | 94,26  | 92,97  | 89,41  | 92,37  | 91,39  | 97,97  |
| <b>F1 Score(%)</b>  | 94,03  | 88,6   | 96,7   | 93,96  | 94,14  | 92,11  | 88,59  | 92,01  | 90,94  | 98,1   |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio (EQM) foram de mil e setecentas épocas (Figura 43).

**Figura 43** - Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 7.



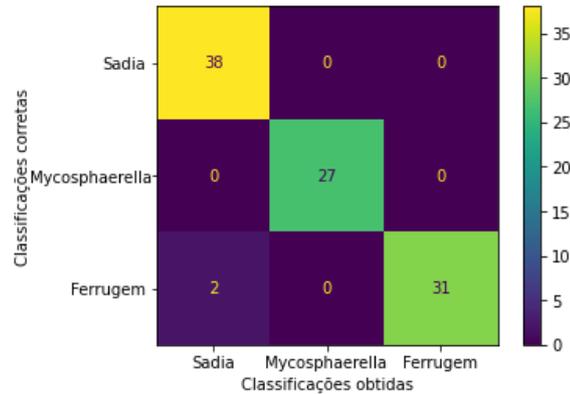
**Fonte:** Autor

Para a convergência da topologia 7, foram necessários em média 3827 épocas, com a maior quantidade no seu primeiro ensaio com 4016 épocas e a menor com 3668 no oitavo ensaio. Nota-se que o número de épocas aumentou conforme a redução de neurônios mesmo com uma camada a mais.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,85%, com sua melhor taxa no décimo ensaio com 97,95% e a menor no segundo ensaio com 88,77%. Outra métrica importante para avaliação da Rede Neural Artificial é o *F1 Score* com média de 92,92%. Com esses resultados a topologia 7, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%, o único problema visualizado por essa rede é a alta taxa de épocas para convergência sendo necessário mais amostras para a suavização do erro quadrático médio.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que a RNA classificou de forma correta todas as folhas saudas e com *Mycosphaerella* e duas folhas com ferrugem foram identificadas como saudas, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 44), gerado pela biblioteca matplotlib.

**Figura 44-** Matriz de confusão de para a topologia 7.  
matriz de confusão de folhas



Fonte: Autor

#### 4.8 – Topologia 8 – 1526 neurônios

A topologia 8 foi definida com 509 neurônios para a primeira camada oculta e 1017 neurônios para a segunda camada oculta utilizando uma das abordagens definidas por Heaton (2008) (Tabela 11).

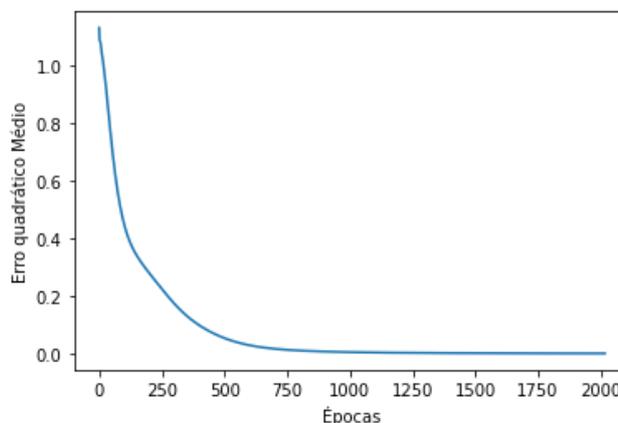
**Tabela 11** - Valores de erro quadrático médio (EQM), épocas, acurácia, precisão, revogação e F1 Score na fase de validação dos ensaios realizados para a topologia 8.

|                     | Ensaio |        |        |        |        |        |        |        |        |        |
|---------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                     | 1      | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| <b>EQM</b>          | 0,1429 | 0,3469 | 0,0306 | 0,2143 | 0,2551 | 0,2041 | 0,2857 | 0,3469 | 0,3367 | 0,1224 |
| <b>Épocas</b>       | 2022   | 2025   | 2055   | 2033   | 1864   | 2033   | 2042   | 1941   | 1945   | 2017   |
| <b>Acurácia(%)</b>  | 94,89  | 89,79  | 96,93  | 93,87  | 92,85  | 91,83  | 89,79  | 89,79  | 87,75  | 96,93  |
| <b>Precisão(%)</b>  | 94,69  | 90,21  | 96,15  | 93,9   | 93,04  | 91,64  | 89,82  | 89,78  | 87,69  | 97,24  |
| <b>Revogação(%)</b> | 95,41  | 89,7   | 97,14  | 94,1   | 93,36  | 92,65  | 90,56  | 90,28  | 88,71  | 97,1   |
| <b>F1 Score(%)</b>  | 94,89  | 89,53  | 96,46  | 93,96  | 93,18  | 91,9   | 89,71  | 89,97  | 88     | 97,16  |

Fonte: Autor

A quantidade mínima de épocas para a estabilização do erro quadrático médio (EQM) foram de seiscentas épocas (Figura 45).

**Figura 45** - Evolução do erro quadrático médio em relação ao número de épocas de treinamento na topologia 8.



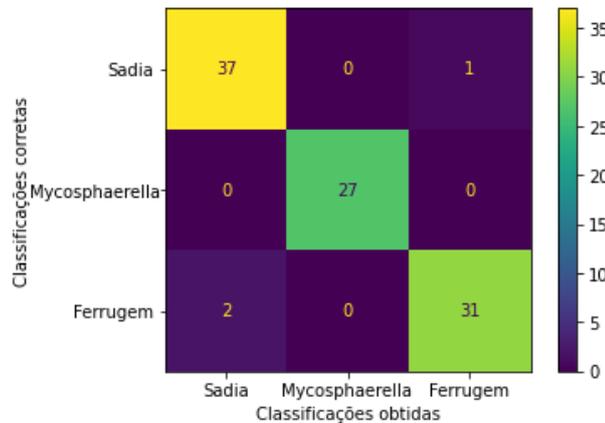
**Fonte:** Autor

Para a convergência da topologia 8, foram necessários em média 1997 épocas, com a maior quantidade no seu terceiro ensaio com 2055 épocas e a menor com 1864 no quinto ensaio. Nota-se que o número de épocas diminuiu consideravelmente em relação a todas as outras topologias analisadas, conforme o aumento de neurônios, podemos notar que existe uma tendência de redução do número de épocas para estabilização do EQM conforme o aumento de neurônios em uma RNA.

Finalizado o processo de aprendizado e testes cruzados, podemos verificar que a rede neural possui uma boa taxa de acertos, com uma acurácia média de 92,44%, com sua melhor taxa no décimo ensaio com 96,93% e a menor no nono ensaio com 87,75%. Outra métrica importante para avaliação da Rede Neural Artificial é o *F1 Score* com média de 92,48%. Com esses resultados a topologia 8, demonstra que possui aplicabilidade em um sistema especialista possuindo índices acima de 90%.

A tabela de confusão dessa topologia, considerando seu ultimo ensaio, mostra que a RNA classificou corretamente todas as amostras de folhas com *Mycosphaerella* e classificou uma folha sadia como uma folha com ferrugem e duas folhas com ferrugem foram identificadas como sadias, o erro pode ter sido ocasionado pela baixa quantidade de amostras com os sintomas de forma leve, dessa forma quantidade de acertos foi bem elevado (Figura 46), gerado pela biblioteca matplotlib.

**Figura 46 - Matriz de confusão de para a topologia 8.**  
matriz de confusão de folhas



Fonte: Autor

#### 4.9 - Comparações entre as topologias

Os resultados mostram que todas as topologias testadas obtiveram taxas de acertos acima dos 90 %, e a quantidade de amostras foi suficiente para o treinamento para a RNA conseguir generalizar entre as três classes propostas pelo presente trabalho.

A tabela de confusão foi utilizada para a classificação da acurácia da rede neural como uma medida de desempenho, além da acurácia foi também calculado o *Precision* (precisão) como métrica de assertividade e o *recall*(revogação) como métrica complementar ao *precision* para toda a classe corretamente classificada levando em consideração todas amostras classificadas como a classe em estudo dando informações necessárias para uma das mais importantes métricas utilizadas para redes neurais que é o *F1 Score* para avaliação da qualidade geral do modelo (SUBRAMANI; FLOUDAS, 2012; LEAL, 2017).

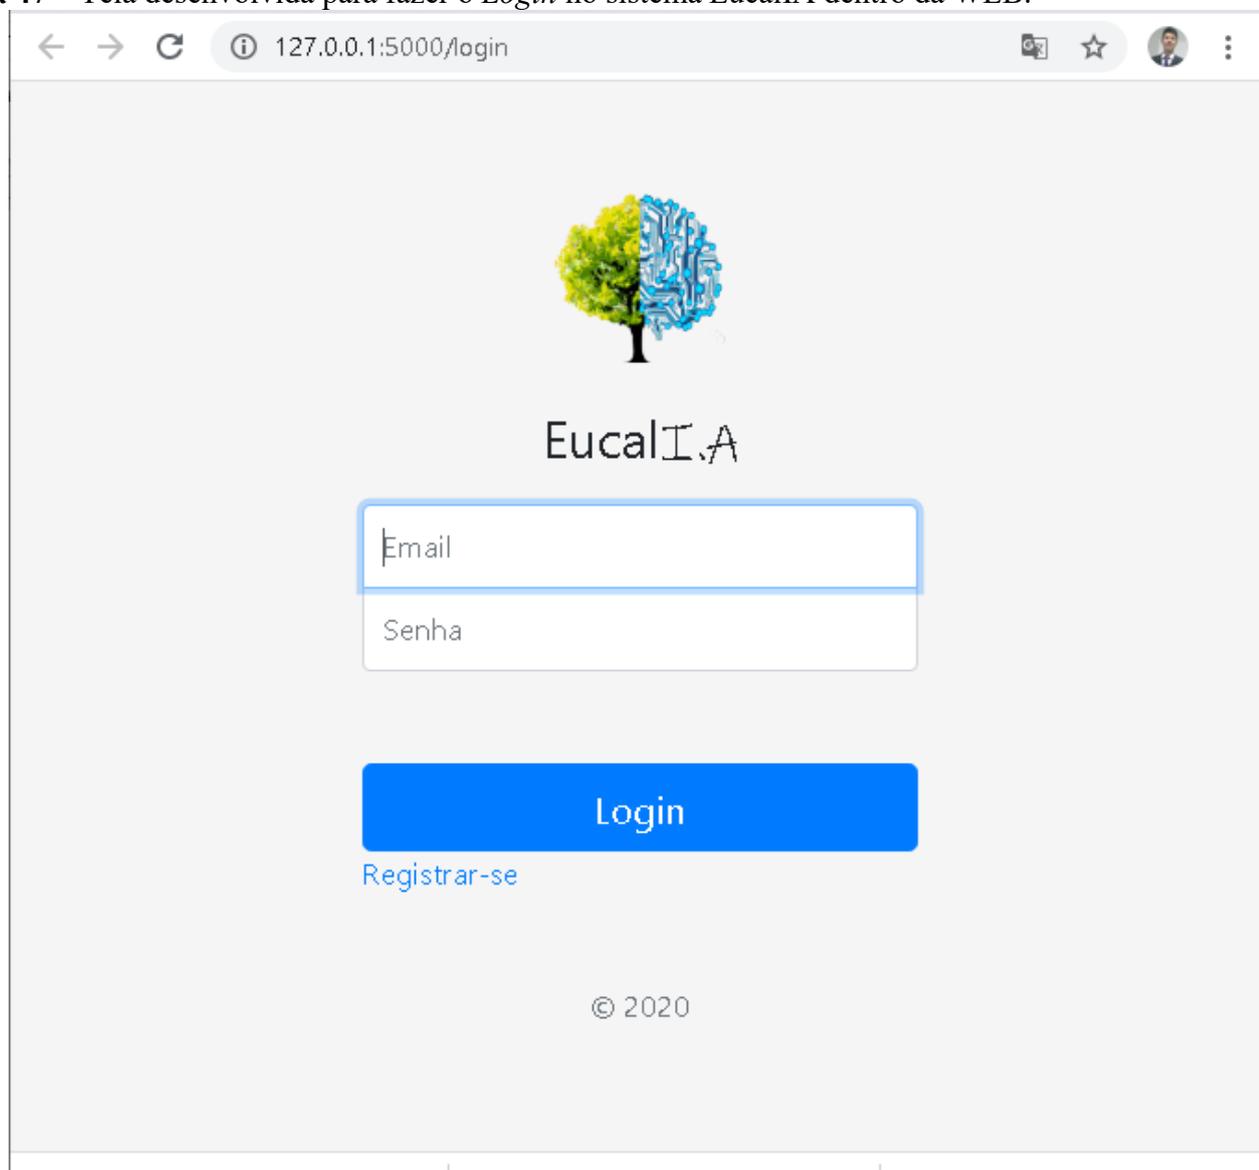
Conforme analisadas as topologias, foi selecionado para a utilização no sistema especialista a topologia 2 pois foi a única que conseguiu manter os principais índices como acurácia, precisão, revogação e *F1 Score* acima dos 93% em média e com o menor EQM de média 0,2133, apenas ficando com um número maior de épocas para convergência, além do modelo com apenas 86 neurônios, economizando poder de processamento e deixando o sistema especialista mais “leve” com o menor custo computacional.

#### 4.10 – Ambiente de execução do sistema

O ambiente de execução do sistema foi elaborado na linguagem *Python* e utilizado a biblioteca *Flask* para a geração de um ambiente WEB. O sistema foi denominado de

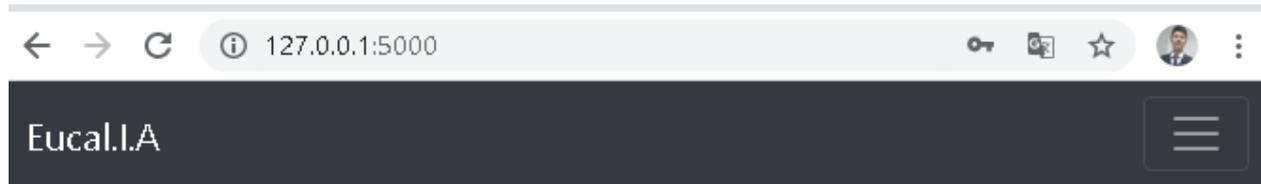
“EucalIA”, possui uma tela em html para login (Figura 47), uma tela principal para o envio de amostras e processamento de respostas (Figuras 48 e 49).

**Figura 47** – Tela desenvolvida para fazer o *Login* no sistema EucalIA dentro da WEB.



Fonte: Autor

**Figura 48** – Tela desenvolvida no sistema EucalIA para envio de folha de eucalipto para análise



## Envio de folhas para análise

Insira a folha aqui

Escolher arquivo

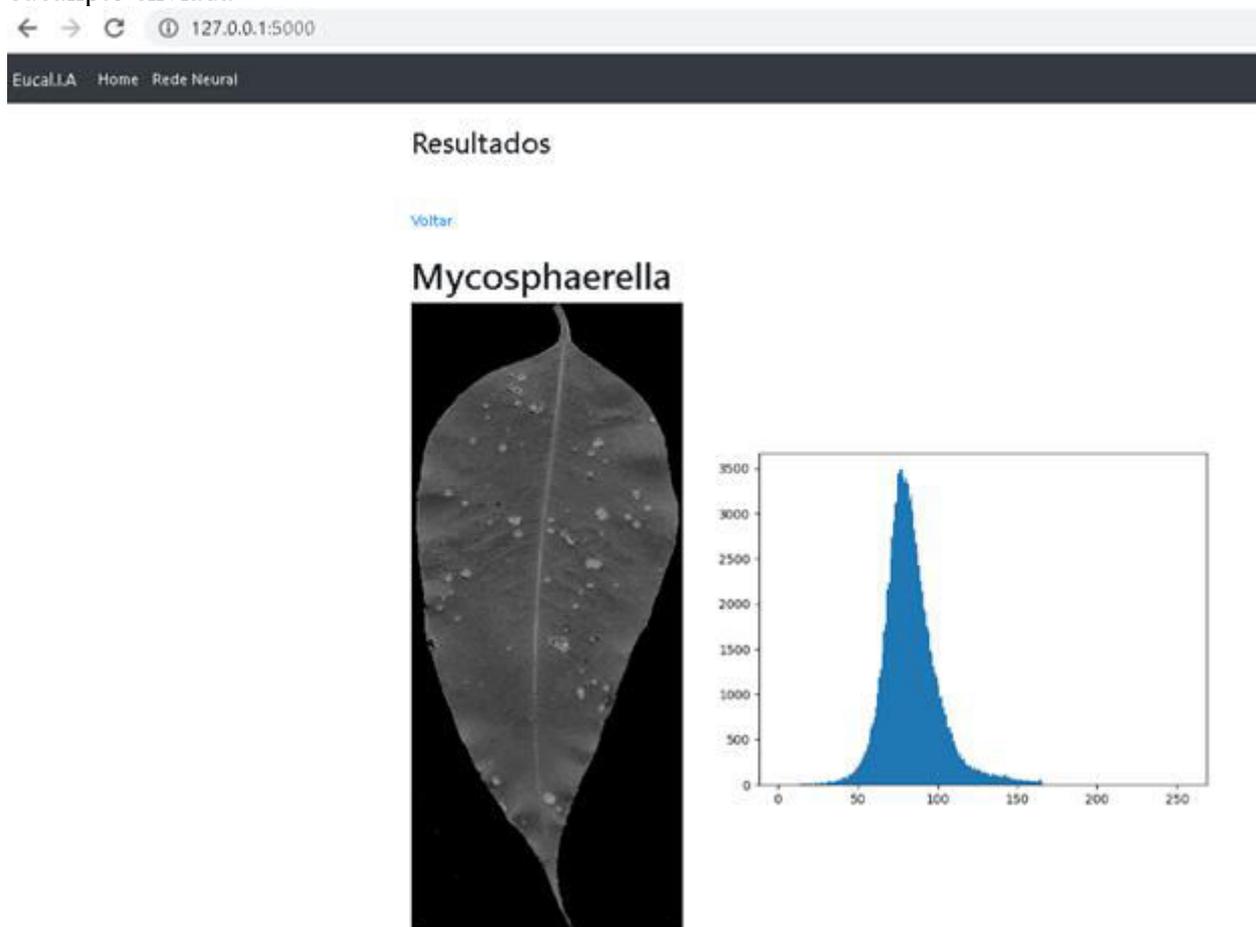
Nenhum arquivo selecionado

Enviar

---

Fonte: Autor

**Figura 49** – Tela desenvolvida no sistema EucallIA com o processamento da imagem de eucalipto enviada



Fonte: Autor

## 5 - Conclusão

A rede neural artificial empregada no sistema especialista foi adequada para o problema proposto, com potencial de agregar novas classes de doenças tornando-o um sistema robusto com a aplicabilidade WEB podendo facilmente ser utilizado por um aplicativo mobile.

Todas as 8 topologias analisadas foram consideradas aptas para integrar o sistema especialista WEB.

Todas as topologias testadas conseguiram altos índices de acertos, precisão e F1 Score acima de 91% e EQM abaixo de 0,3 resultando em uma ótima performance para a rede.

O presente trabalho contempla a criação de uma sistema especialista baseado em visão computacional(Pré-processamento de imagens) e de inteligência Artificial para a diagnose de doenças foliares do eucalipto. Dessa forma podemos concluir que é viável a construção de uma ferramenta para auxílio no manejo integrado de doenças para um melhor controle

fitossanitário de florestas e viveiros para auxiliar em uma correta tomada de decisão quanto às ações de controle de doenças após a correta diagnose.

## **6 - Considerações finais**

Foi identificado que com quanto maior o número de neurônios é possível diminuir a quantidade de épocas para estabilização do EQM, sendo assim para grandes quantidades de amostras provavelmente será necessário o incremento de neurônios da RNA.

Ao longo do desenvolvimento deste estudo foi possível identificar questões que permitiriam o desenvolvimento de outros estudos como, melhora do processamento de imagens tiradas por *smartphones*, quantificação em percentual da área atacada pela doença, utilização de localização para posterior mapeamento de focos em determinada região contribuindo para a criação de um sistema especialista robusto e integrado com diversas tecnologias.

## 7 - REFERÊNCIAS BIBLIOGRÁFICAS

- ALFENAS, A. C.; ZAUZA A. A. V.; MAFIA, R. G.; ASSIS, T. F. **Clonagem e doenças do eucalipto** 2.ed. Viçosa, MG: Universidade Federal de Viçosa, 2009. 500p.
- BALLARD, D. H. ; BROWN, C. M. **Computer Vision**. 1.Ed. Englewood Cliffs: Prentice-Hall, 1987.
- BARELLI, F. **Introdução à Visão Computacional: Uma abordagem prática com Python e OpenCV**. 1.Ed, São Paulo: Casa do Código, 2018.
- BATMAVADY, S.; SAMUNDEESWARI, S. **Detection of cotton leaf diseases using image processing**, International Journal of Recent Technology and Engineering, 8(2 Special Issue 4), pp. 169-173, 2019 DOI: 10.35940/ijrte.B1031.0782S419
- DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo: Artliber, 2010.
- FAVAN J. R.; **Utilização de redes neurais artificiais aplicadas na discriminação de padrões de doenças florestais**. Dissertação (Mestrado em ciência Florestal) - Faculdade de Ciências Agrônômicas da UNESP – Campus de Botucatu, Botucatu, p. 69. 2015.
- FUENTES, A.; YOON, S.; KIM, S.C.; PARK, D.S. **A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition**. Sensors 2017, 17, 2022. <https://doi.org/10.3390/s17092022>.
- GANESAN V.; **Agricultural expert system for the diagnosis of pests and diseases**, 15th International Workshop on Artificial Intelligence in Agriculture AIA-2004, IFAC, Cairo, Egito, Mar. 8-10, pp. 107-110.
- GERÓN, A.; **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow Conceitos, Ferramentas e Técnicas para a Construção de Sistemas Inteligentes** 1. Ed. 1. Ed. Rio de Janeiro: Alta Books, 2019.
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 1. ed. São Paulo: Blucher, 2009.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2.Ed. Porto Alegre: Bookman, 2001.
- HAHN, F. **Actual Pathogen Detection: Sensors and Algorithms - a Review**. Algorithms 2009, 2, 301-338. <https://doi.org/10.3390/a2010301>
- HEATON, J.; **Introduction to Neural Networks for Java**. 2.Ed. Chesterfield: Heaton Research, Inc, 2008.
- KIRUTHIKA, U.; KANAGASUBA RAJA, S.; JAICHANDRAN, R.; PRIYADHARSHINI, C., **Detection and Classification of Paddy Crop Disease using Deep Learning**

**Techniques.** International Journal of Recent Technology and Engineering (IJRTE), 8 (3), pp. 4353-4359, 2019, doi: 10.35940/ijrte.C5506.098319.

Indústria Brasileira de Árvores - IBÁ. 2020. **Dados Estatísticos.** Disponível em: <<https://www.iba.org/dados-estatisticos>> 04 de jun. 2021.

Instituto Brasileiro de Geografia e Estatística. IBGE. **Produção da extração vegetal e da silvicultura.** Rio de Janeiro, 2020. Disponível em: <[https://biblioteca.ibge.gov.br/visualizacao/periodicos/74/pevs\\_2019\\_v34\\_informativo.pdf](https://biblioteca.ibge.gov.br/visualizacao/periodicos/74/pevs_2019_v34_informativo.pdf)> Acesso em 04 jun. 2021.

JESUS JUNIOR, W. C.; VALE, F.X.R.; BERGAMIN FILHO, A. Capítulo 7. Quantificação de danos e perdas. In: VALE, F.X.R.; JESUS JUNIOR, W.C. DE; ZAMBOLIM, L. (Editores). **Epidemiologia Aplicada ao Manejo de Doenças de Plantas.** Belo Horizonte: Editora Perffil, 2004, v.1, p.227-298.

LEAL, S. R.; **Métricas Comuns em Machine Learning: como analisar a qualidade de chat bots inteligentes — métricas (3 de 4).** In: medium, 2017 Disponível em:< <https://medium.com/as-m%C3%A1quinas-que-pensam/m%C3%A9tricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots-inteligentes-m%C3%A9tricas-1ba580d7cc96>> Acesso em: 12 abr. 2020

LUTZ, M.; ASCHER D.; **Aprendendo Python.** 2. Ed. Porto Alegre: O'Reilly, 2007.

MAFFIA, R.G. ; FERREIRA, M. A. ; JESUS JUNIOR, W.C.; Diagnose manejo integrado das doenças do eucalipto em viveiros e florestas de produção. In: Silva E.N; FIEDLERM N.C; PEREIRA D.P; PAULA M.O. (Org.). **Florestas de Produção.** 1ed.Alegre: Suprema, 2014, v.1, p.99-138.

MOHANTY, S.P.; HUGHES, D.P.; SALATHÉ, M. **Using deep learning for image-based plant disease detection,** *Frontiers in Plant Science.* 2016, v7 p.1419 <https://doi.org/10.3389/fpls.2016.01419>.

NGUGI, L. C.; ABELWAHAB, M.; ABO-ZAHHAD M. **Recent advances in image processing techniques for automated leaf pest and disease recognition – A review,** *Information Processing in Agriculture,* 2021. <https://doi.org/10.1016/j.inpa.2020.04.004>

PASSADOR, M. M.; MARUBAYASHI, J. M.; UZZO, R. P. et al. **Influence of Mycosphaerella and Teratosphaeria leaf diseases on chemical composition of essential oils of Eucalyptus globulus and effect of these essential oils on ascospores germination.** *Arch Microbiol* (2021). <https://doi-org.ez31.periodicos.capes.gov.br/10.1007/s00203-021-02324-4>

REDDY, K. K.; SOLMAZ, B; YAN, P.; AVGEROPOULOS, N. G.; RIPPE, D. J.; SHAH, M. **Confidence guided enhancing brain tumor segmentation in multi-parametric MRI.** 2012. Disponível em: [https://www.crcv.ucf.edu/papers/ISBI\\_2012.pdf](https://www.crcv.ucf.edu/papers/ISBI_2012.pdf).

REZENDE, H.E.; AUER, C.G.; HIGA, A.R.; SANTOS, A.F. DOS; SILVA, L.D.; DUIN, I.M.; COELHO, T.A.V.; SOARES, I.D. **Evaluation of resistance in Eucalyptus grandis progenies against leaf spot of Cylandrocladium and Kirramyces.** *Summa Phytopathologica,* v.45, n.3, p.295-301, 2019 DOI: <https://doi.org/10.1590/0100-5405/191990>

SHABARI SHEDTHI, B.; SIDDAPPA, M.; SHETTY, S. **Identification of plant leaf disease using machine learning techniques**. International Journal of Recent Technology and Engineering 8(3), pp. 6077-6081. 2019 DOI: 10.35940/ijrte.C5621.098319.

STALLMAN, R. **O que é o software livre?** Disponível em: <<https://www.gnu.org/philosophy/free-sw.html>>. Acesso em: 10 jun. 2020.

SUBRAMANI, A.; FLOUDAS, C. A.  **$\beta$ -sheet Topology Prediction with High Precision and Recall for  $\beta$  and Mixed  $\alpha/\beta$  Proteins**. PLoS ONE, v. 7, n. 3, p. 1–9, mar. 2012.

UDAWANT, P., SRINATH, P. **Diseased portion classification & recognition of cotton plants using convolution neural networks**, International Journal of Engineering and Advanced Technology 8(6), pp. 3492-3496, 2019 DOI: 10.35940/ijeat.F9526.088619.

VALE, F.X.R.; JESUS JUNIOR, W.C.; LIBERATO, J.R.; SOUZA, C.A. Quantificação de doenças e do crescimento do hospedeiro. In: VALE, F.X.R.; JESUS JUNIOR, W.C. DE; ZAMBOLIM, L. (Editores). **Epidemiologia Aplicada ao Manejo de Doenças de Plantas**. Belo Horizonte: Editora Perffil, 2004, v.1, p.89-124.

VELÁSQUEZ, D.; SÁNCHEZ, A.; SARMIENTO, S.; TORO, M.; MAIZA, M.; SIERRA, B. **A Method for Detecting Coffee Leaf Rust through Wireless Sensor Networks, Remote Sensing, and Deep Learning: Case Study of the Caturra Variety in Colombia**. Appl. Sci. 2020, 10, 697. <https://doi.org/10.3390/app10020697>

ZHANG Y.; SONG C.; ZHANG D., **Deep Learning-Based Object Detection Improvement for Tomato Disease**, IEEE Access, vol. 8, pp. 56607-56614, 2020, doi: 10.1109/ACCESS.2020.2982456.