

UNIVERSIDADE ESTADUAL DO PIAUÍ - UESPI  
CAMPOS PROF. ALEXANDRE ALVES DE OLIVEIRA  
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

RENAN FIALHO DO NASCIMENTO

REDE NEURAL ARTIFICIAL E PROCESSAMENTO DIGITAL DE IMAGEM PARA  
RECONHECIMENTO DE FOLHAS DE DUAS ESPÉCIES DA FAMÍLIA  
*PLECTRANTHUS*

Biblioteca UESPI PMB  
Registro Nº \_\_\_\_\_  
COD 004.61  
GUTTER N 2447  
V \_\_\_\_\_ EX. 01  
Data 28 10 2015  
Voto \_\_\_\_\_

PARNAÍBA

2015

**RENAN FIALHO DO NASCIMENTO**

**REDE NEURAL ARTIFICIAL E PROCESSAMENTO DIGITAL DE IMAGEM PARA  
RECONHECIMENTO DE FOLHAS DE DUAS ESPÉCIES DA FAMÍLIA  
*PLECTRANTHUS***

Monografia submetida ao Curso de Bacharelado em  
Ciência da Computação da Universidade Estadual do  
Piauí, como parte dos requisitos para obtenção do  
título de Bacharel em Ciência da Computação.

Orientador: Prof. Msc. Dario Brito Calçada.

**PARNAÍBA**

**2015**

N244r

Nascimento, Renan Fialho do.

Rede neural artificial e processamento digital de imagem para reconhecimento de folhas de boldo da Farmácia Viva / Renan Fialho do Nascimento. Parnaíba: UESPI, 2015.

46 f. : il.

Orientador: MSc. Dario Brito Calçada.

Monografia (Graduação em Ciência da Computação) –  
Universidade Estadual do Piauí, 2015.

1. Redes neurais 2. Processamento digital de imagens 3. Folhas  
I. Calçada, Dario Brito II. Universidade Estadual do Piauí III. Título

CDD 004.61

**RENAN FIALHO DO NASCIMENTO**

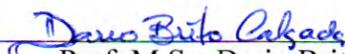
**REDE NEURAL ARTIFICIAL E PROCESSAMENTO DIGITAL DE IMAGEM PARA  
RECONHECIMENTO DE FOLHAS DA FAMÍLIA PLECTRANTHUS**

Monografia apresentada ao Curso de Bacharelado em Ciência da Computação da Universidade Estadual do Piauí – UESPI, Campus Prof. Alexandre Alves de Oliveira, como parte das exigências da disciplina de Estágio Supervisionado, requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Orientador: M.Sc. Dario Brito Calçada

Monografia Aprovada em: **24 de julho de 2015.**

Banca Examinadora:



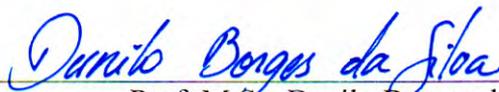
---

Prof. M.Sc. Dario Brito Calçada  
UESPI/Parnaíba – Orientador



---

Prof. M.Sc. Eyder Franco Sousa Rios  
UESPI/Parnaíba – Avaliador



---

Prof. M.Sc. Danilo Borges da Silva  
UFC/Fortaleza – Avaliador

Dedico a Deus que até aqui me deu forças para não desistir e coragem para enfrentar as dificuldades que vieram pelo caminho. A minha mãe, a meus irmãos pelas palavras de encorajamento e incentivo. A minha amiga Quéren-Hapuque, que em muitas conversas me incentivou e me ajudou a pensar em soluções para este trabalho.

## AGRADECIMENTOS

Principalmente a Deus que permitiu chegar até aqui, ter vivido e aprendido com erros e acertos.

Aos meus pais Maria e Francisco (em memória) por existir, exemplos, conselhos e amor.

A minha irmã Regiane, pelo amor fraternal e ajuda na correção ao decorrer da escrita deste trabalho.

Ao professor e amigo, Dario Calçada por sugerir o tema e pela orientação e paciência durante todo o trabalho.

A todos que fazem o polo da Farmácia Viva no município de Parnaíba-PI pelas amostras cedidas e pelo auxílio à pesquisa.

Aos meus amigos e irmãos em Cristo do Ministério de Dança Kyrio's que há 7 anos estão ao meu lado, apoiando-me, aconselhando e dividindo momentos importantes para mim.

A todos aqueles que, em algum momento ou em conversas rápidas incentivaram e acreditaram em mim.

## RESUMO

O uso de plantas com ações comprovadas no tratamento de doenças é uma realidade social presente na cidade de Parnaíba-PI, cujo projeto de horto medicinal Farmácia Viva encarrega-se de difundir. O processo de reconhecimento e classificação dessas plantas demandam análises e métodos que garantam que a espécie tenha realmente esse uso. A aplicação de técnicas computacionais para automação das atividades de reconhecimento de plantas motivou esta pesquisa. As Redes Neurais Artificiais em conjunto com Processamento Digital de Imagens proporcionam uma alta capacidade em resolução de problemáticas de reconhecimento de padrões, sendo possível encontrar diversas aplicações que usam estas técnicas em conjunto. O horto da Farmácia Viva conta com dois espécimes da mesma família que apresentam características semelhantes entre si e aplicações médicas distintas. Objetivou-se desenvolver um estudo sobre processamento digital de imagens e redes neurais artificiais para automação do processo de identificação e catalogação das espécies por meio do órgão foliar (limbo e pecíolo), extraindo características anatômicas e morfológicas que compõe as amostras, usando o conjunto de informações adquiridas como parâmetros de entrada de uma rede neural artificial do tipo *Perceptron* Multicamadas. Obteve-se um conjunto de amostras, por meio de coleta, ao visitar o projeto de socialização de plantas medicinais, onde se coletou folhas das duas espécies da família *Plectranthus*. Por comparações entre os espécimes e técnicas de processamento de imagem, foi possível a obtenção dos dados característicos de cada planta, que foram utilizados como parâmetros de treinamento, validação e teste da rede neural artificial. Os resultados alcançados mostraram-se satisfatórios, levando em consideração as técnicas e procedimentos usados por outros pesquisadores sobre a mesma perspectiva, encontrados na literatura. A Rede Neural *Perceptron* Multicamadas alcançou a taxa de acerto equivalente a 96,15% para o conjunto de teste, confirmando a relação do conjunto de características selecionadas e a eficiência da técnica de inteligência computacional escolhida.

**PALAVRAS-CHAVE:** Processamento Digital de Imagem. *Perceptron* Multicamadas. Folhas. Redes Neurais Artificiais. Reconhecimento de Padrões.

## ABSTRACT

The use of plants with proven actions in the treatment of diseases is a social reality present in Parnaíba-PI, whose medicinal garden project Farmácia Viva is responsible for spreading. The process of recognition and classification of these plants require analysis and methods to ensure that your medicinal use. The application of computational techniques for automation activities of plant recognition was motivation this research. The Artificial Neural Networks in conjunction with Digital Image Processing can capability to solve problems like pattern recognition, is possible to find various applications that use the union this techniques. The garden of Farmácia Viva has two specimens' plants of the same family that have similar characteristics to each other and different medical applications. The objective was to develop a study on digital image processing and artificial neural networks for automation of the process of identifying and cataloging species through leaf (limb and petiole), extracting anatomical and morphological characteristics with the processing of the images that make up the samples, using the set of acquired information as input parameters for an artificial neural multilayer perceptron network. Collected a set of samples, when visiting the socialization project of medicinal plants, where was acquired five leaves of two species of family Plectranthus. In comparisons between specimen and image processing techniques, the plants leaves were traced data that characterize him, and were too utilized in the neural network training, validation and testing. The results obtained were satisfactory, taking into consideration the techniques and procedures used by other researchers in the same perspective, found in the literature. The Neural Network Multilayer Perceptron reached the hit rate equivalent to 96.15% for the test set, confirming the relationship of the set of selected features and efficiency of the chosen neural network.

**KEYWORDS:** Digital Image Processing. Multilayer Perceptron. Sheets. Artificial Neural Network. Pattern Recognition.

## LISTA DE FIGURAS

<b>Figura 1.</b> Corte transversal do olho.....	15
<b>Figura 2.</b> Diversos tipos de interação da radiação com a matéria.....	17
<b>Figura 3.</b> Elementos de um sistema de processamento de imagem.....	17
<b>Figura 4.</b> (a) Imagem original; (b) Imagem contaminada por ruído impulsivo (sal e pimenta); (c) Resultado da filtragem pelo filtro mediana com máscara 3x3.....	21
<b>Figura 5.</b> Neurônio biológico.....	25
<b>Figura 6.</b> Conexões sinápticas entre neurônios.....	26
<b>Figura 7.</b> Neurônio artificial.....	27
<b>Figura 8.</b> Arquiteturas (a) Rede <i>feedforward</i> de camada simples, (b) Rede <i>feedforward</i> multicamadas e (c) Rede recorrente.....	28
<b>Figura 9.</b> Arquitetura da Rede <i>Perceptron</i> Multicamadas.....	30
<b>Figura 10.</b> (a) Boldo ( <i>Plectranthus amboinicus</i> ), (b) Malva ( <i>Plectranthus barbatus</i> ).....	32
<b>Figura 11:</b> Folha de Boldo à esquerda e Malva a direita, escala de cinza.....	33
<b>Figura 12:</b> (a) Área selecionada para extração do conjunto de cores no pecíolo; (b) Ferramenta <i>Straight</i> para indicar o comprimento.....	34
<b>Figura 13.</b> Técnicas de escala de cinza e binarização: (a) Exemplo do processamento da imagem de Boldo, (b) Exemplo do processamento da imagem da Malva.....	38
<b>Figura 14.</b> Representação da melhor configuração da RNA encontrada pelo processo de validação cruzada.....	39
<b>Figura 15.</b> Gráfico resultante do conjunto de treinamento, realizado na rede neural MLP. ...	40
<b>Figura 16.</b> Gráfico de comparação entre os novos dados inseridos com as saídas desejadas, sob o conjunto de teste.....	40
<b>Figura 17.</b> Relação dos resultados obtidos nas fases de treinamento, validação e teste. Saídas desejadas (○) Saídas da RNA (●).....	41

## LISTA DE TABELAS

<b>Tabela 1.</b> Dados adquiridos com o processamento de imagens .....	35
<b>Tabela 2.</b> Conjunto de dados de treinamento, validação e teste.....	36
<b>Tabela 3.</b> Relação entre a resolução e a matriz de pixels dos dispositivos utilizados para realizar a captura das imagens.....	37

## SUMÁRIO

<b>CAPÍTULO 1– INTRODUÇÃO .....</b>	<b>11</b>
<b>CAPÍTULO 2– PROCESSAMENTO DIGITAL DE IMAGENS.....</b>	<b>14</b>
2.1 Histórico .....	14
2.2 Olho humano .....	14
2.3 Sistema típico de imagem digital .....	16
2.4 Imagem digital.....	18
2.5 Processamento Digital de Imagem (PDI) .....	19
2.5.1 Técnica de Transformação em nível de cinza .....	20
2.5.2 Técnica de Contraste .....	20
2.5.3 Técnica de Suavização (Filtro da mediana) .....	21
2.5.4 Técnica de Segmentação (Limiarização) .....	22
<b>CAPÍTULO 3– REDES NEURAIS ARTIFICIAIS.....</b>	<b>23</b>
3.1 Histórico .....	23
3.2 Neurônio Biológico X Neurônio Artificial .....	24
3.3 Arquiteturas de Redes Neurais Artificiais.....	27
3.4 Treinamento de uma RNA.....	28
3.4.1 Treinamento supervisionado .....	29
3.5 Redes <i>Perceptron</i> Multicamadas.....	28
<b>CAPÍTULO 4– MATERIAIS E MÉTODOS.....</b>	<b>32</b>
4.1 Amostras das folhas da família <i>Plectranthus</i> .....	32
4.2 Aquisição e processamento das imagens.....	33
4.3 Rede Neural <i>Multilayer Perceptron</i> (MLP) .....	35
<b>CAPÍTULO 5– RESULTADOS E DISCUSSÃO .....</b>	<b>37</b>
<b>CAPÍTULO 6– CONSIDERAÇÕES FINAIS.....</b>	<b>42</b>
<b>REFERÊNCIAS .....</b>	<b>43</b>

## INTRODUÇÃO

O Brasil concentra uma grande biodiversidade com uma rede de plantas das mais diversas espécies. As plantas são seres vivos encontrados em todo o planeta. Sua estrutura básica é composta por raiz, caule, folha, flor e fruto. Dependendo da sua classificação biológica, estas apresentam diferenças quanto à estrutura (VIDAL; VIDAL, 2006).

As plantas são responsáveis pelo manejo do nosso oxigênio, ao realizar fotossíntese, produzir frutos e, em algumas espécies, seus componentes são usados como matéria-prima na fabricação de móveis e medicamentos. O uso de plantas medicinais no Brasil é um traço cultural marcante e figura como uma alternativa para as pessoas que não possuem acesso à Medicina tradicional. A medicina popular tem sido usada no tratamento e na cura de doenças nas regiões mais carentes do país, assim como em grandes cidades brasileiras e isso se dá em grande parte por meio do uso de plantas medicinais que são comercializadas em feiras livres, mercados populares e encontradas em quintais de residências (SOUZA et al., 2013).

Os fitoterápicos são medicamentos preparados com plantas ou partes de plantas que possuem propriedades reconhecidas de cura, prevenção, diagnóstico ou tratamento sintomático de doenças, validadas em estudos etnofarmacológicos (ARNOUS *et al.*, 2005).

Na categoria de plantas medicinais, a identificação e a comprovação do seu uso pode ser um processo muito demorado. Uma espécie de planta pode variar quanto ao seu gênero e apontar traços bastante semelhantes à outra da mesma família e contando com aplicações medicinais bem distintas. Pesquisadores têm utilizado a folha como chave para classificação automática de plantas (KADIR *et al.*, 2011; ULUTURK; UGUR, 2012). Uma identificação exata do tipo e espécie da planta é possível com uma análise em laboratório, o que exige uso de métodos como celular e molecular (WU *et al.*, 2007).

A Farmácia Viva é um projeto de socialização de plantas medicinais desenvolvido pelo Prof. Dr. Francisco José de Abreu Matos da Universidade Federal do Ceará (MATOS, 2000), com um pequeno polo localizado na cidade de Parnaíba-PI, que atua no desenvolvimento e distribuição de mudas vegetais, contando com um horto de plantas medicinais. Neste polo encontram-se disponibilizados 16 tipos de plantas, cujo uso é comprovado cientificamente por técnicas laboratoriais na ação fitoterápica.

O desenvolvimento de tecnologias computacionais, métodos de processamento de sinais e imagens tem motivado uma tendência crescente na automação de técnicas tanto na indústria quanto na pesquisa e outros setores da sociedade. O reconhecimento de plantas não é uma exceção (SILVA, 2013). O processamento e a interpretação automática de imagens captadas por satélites auxiliam os trabalhos nas áreas de Geografia, Sensoriamento Remoto, Geoprocessamento e Meteorologia, dentre outras.

Técnicas de restauração de imagens auxiliam arqueólogos a recuperar fotos borradas de artefatos raros, já destruídos. O uso de robôs dotados de visão artificial em tarefas tais como controle de qualidade em linhas de produção aumenta a cada ano, num cenário de crescente automação industrial (FILHO; NETO, 1999).

O processamento digital de imagens busca melhorar o aspecto visual de certas feições estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos (SILVA, 2005).

As aplicações que envolvem a utilização de redes neurais artificiais são as mais variadas possíveis, como por exemplo: avaliação de imagens captadas por satélite; classificação de padrões de escrita e fala; identificação de anomalias em imagens médicas, entre outras. Os métodos de processamento de imagens associados a técnicas de redes neurais artificiais proporcionam metodologias para identificação automática de padrões, extração de informações (SILVA; SPATTI; FLAUZINO, 2010).

O objetivo desta pesquisa foi mostrar um estudo de técnicas computacionais de processamento de imagens e redes neurais artificiais, para classificação automática de folhas de Boldo Nacional ou Malva-Santa (*Plectranthus amboinicus*) e Malvariço ou Malva (*Plectranthus barbatus*) que pertencem à mesma família, porém com propriedades medicinais totalmente distintas. Para que fosse alcançado este objetivo, as seguintes etapas precisaram ser definidas: (a) analisar toda a estrutura das folhas; (b) avaliar técnicas de processamento de imagens que identifiquem folhas; (c) definir o conjunto de entrada para treinamento da rede neural artificial; (d) realizar o treinamento das redes neurais para obtenção de resultado otimizado.

Para realização deste trabalho, as tarefas foram divididas em etapas sequenciais. Primeiramente foram pesquisados e revisados conhecimentos sobre as áreas relacionadas por intermédio de levantamento bibliográfico e aprofundamento na área de botânica sistemática e

análise morfológica das plantas. Em seguida, um levantamento de técnicas utilizadas para processamento de imagem a fim de obter a extração de características das imagens das folhas.

Após processar as imagens e selecionar as características apontadas como critérios para diferenciação, os resultados obtidos foram aplicados em uma rede neural *Multilayer Perceptron* (MLP), com o procedimento de treinamento supervisionado, que apontará como saída a identificação da espécie pesquisada.

Esta monografia está dividida em seis capítulos, onde serão brevemente comentados.

O atual capítulo, **INTRODUÇÃO**, apresenta uma visão total dos principais pontos desta pesquisa, considerando alguns pontos importantes como a justificativa, problemática, objetivos e metodologia utilizada na resolução do problema.

O capítulo 2, **PROCESSAMENTO DIGITAL DE IMAGENS**, mostra alguns conceitos relevantes para a compreensão do tema da atual pesquisa.

O capítulo 3, **REDES NEURAS ARTIFICIAIS**, apresenta alguns conceitos importantes sobre esta técnica de inteligência computacional, bem como a explicação da rede neural utilizada neste trabalho.

O capítulo 4, **MATERIAIS E MÉTODOS**, mostra como foram usadas às ferramentas utilizadas neste trabalho, assim como detalhes técnicos. Neste capítulo será apresentado como os dados foram coletados e processadas as imagens e também como foi realizado o treinamento, validação e teste da rede neural MLP.

O capítulo 5, **RESULTADOS E DISCUSSÃO**, mostra o desenvolvimento final deste trabalho, como a utilização das técnicas proporcionou o alcance dos resultados, expondo as melhores métricas realizadas no processamento de imagem e a eficiência da rede neural artificial.

O último capítulo, **CONSIDERAÇÕES FINAIS**, contém algumas observações acerca do trabalho desenvolvido. São apresentadas também, algumas sugestões de melhorias para a exploração de dados em redes neurais no tópico de trabalhos futuros.

## **CAPÍTULO 2**

### **PROCESSAMENTO DIGITAL DE IMAGENS**

#### **2.1 HISTÓRICO**

As imagens desenvolveram-se com o passar dos anos nos mais diversos seguimentos científicos: da Astronomia à Matemática, das Matemáticas à Meteorologia, da Informática à Biologia, etc. Nestes diferentes seguimentos, as imagens são simplesmente visualizações de fenômenos (JOLY, 2007).

Historicamente na área da Informática, a Computação Gráfica e o Processamento Digital de Imagem tiveram grande marco no aprimoramento de informações para interpretação humana, onde se podem citar os primeiros sistemas *Bartlane* (GONZALEZ; WOODS, 2002). No início da década de 20, as imagens eram codificadas em cinco níveis de intensidade distintos, logo, passaram para quinze níveis, ao mesmo tempo em que era desenvolvido um método aprimorado de revelação de filmes por meio de feixes de luz modulados por uma fita que continha informações codificadas sobre a imagem (AZEVEDO; CONCI, 2003).

Em 1964, técnicas computacionais foram utilizadas para aprimoramento de vários tipos de distorções de imagens vindas da Lua, enviadas pela sonda *Ranger*. Mais tarde, no ano de 1969 nos laboratórios da Bell, foi construída a primeira matriz de pixels (cada pixel representado por 3 bits) (AZEVEDO; CONCI, 2003; FILHO; NETO, 1999).

Atualmente a área de processamento de imagens vem apresentando crescimento em diversos ramos da atividade humana. Na Medicina, o uso de imagens para diagnóstico tornou-se rotineiro e os avanços em processamento de imagens vêm permitindo mais facilmente a interpretação dos resultados. O processamento e a interpretação automática de imagens captadas por satélites auxiliam os trabalhos nas áreas da Geografia, Sensoriamento Remoto, Geoprocessamento, dentre outros (FILHO; NETO, 1999).

#### **2.2 OLHO HUMANO**

O globo ocular tem formato esférico com um diâmetro de cerca de 20 milímetros. Dividido em três membranas: córnea/esclerótica formam uma camada mais externa, coróide e a retina as outras duas membranas (Figura 1). A córnea é uma película transparente que cobre a superfície anterior do olho e continua a ela. A esclerótica é uma membrana opaca que encobre o restante do globo ótico (FILHO; NETO, 1999).

A coróide é uma membrana que contém uma rede de vasos sanguíneos que servem como principal fonte de nutrição do olho. Seu revestimento é fortemente pigmentado, o que ajuda a inibir a quantidade de luz que chega ao olho. A coróide é dividida em corpo ciliar e diafragma da íris (ou simplesmente íris), responsável por controlar a passagem de luz (FILHO; NETO, 1999).

A câmara mais interna do olho é a retina, situada na sua parede posterior. Quando o olho focaliza uma cena, a imagem correspondente é projetada sobre a retina, que possui dois tipos de foto sensores, os cones (sensíveis a cores e com alta resolução, operando apenas em cenas suficientemente iluminadas) e os bastonetes (não distinguem cores, mas são especializados em ambientes com ausência de luz), responsáveis pela conversão de energia luminosa em impulsos elétricos que serão transmitidos para o cérebro, para posterior interpretação (EUSTÁQUIO; QUEIROZ; GOMES, 2001).

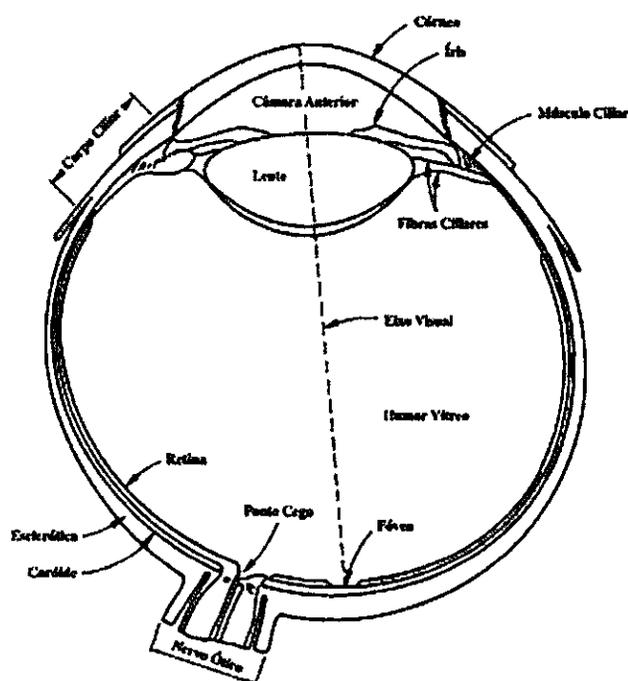


Figura 1. Corte transversal do olho.

Fonte: (MARQUES FILHO, Ogê; VIEIRA NETO, Hugo, 1999)

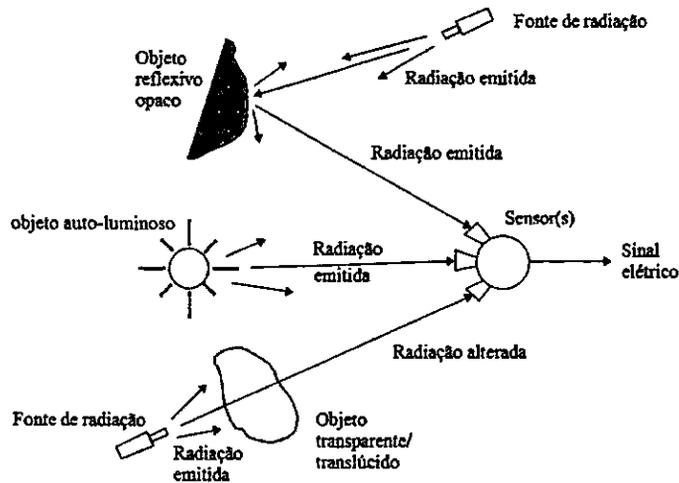
A visualização de um objeto consiste do posicionamento do olho pela estrutura que o controla, implicando a projeção da imagem do objeto sobre a fóvea (EUSTÁQUIO; QUEIROZ; GOMES, 2001).

### 2.3 SISTEMA TÍPICO DE IMAGEM DIGITAL

As imagens são geradas pela combinação de uma fonte de iluminação e reflexão ou absorção de energia a partir dos elementos da “cena” que está sendo exibida. Para obter uma imagem digital necessita-se de dois elementos. Primeiro, um dispositivo físico (sensor) que seja sensível à energia irradiada pelo objeto o qual se quer obter a imagem. O segundo, chamado digitalizador, é um dispositivo para converter a saída do dispositivo de detecção física para a forma digital (GONZALEZ; WOODS, 2002). Corroborando com D’Amico; Di Natale; Sarro (2015, p. 2) e colaboradores os sensores são definidos como:

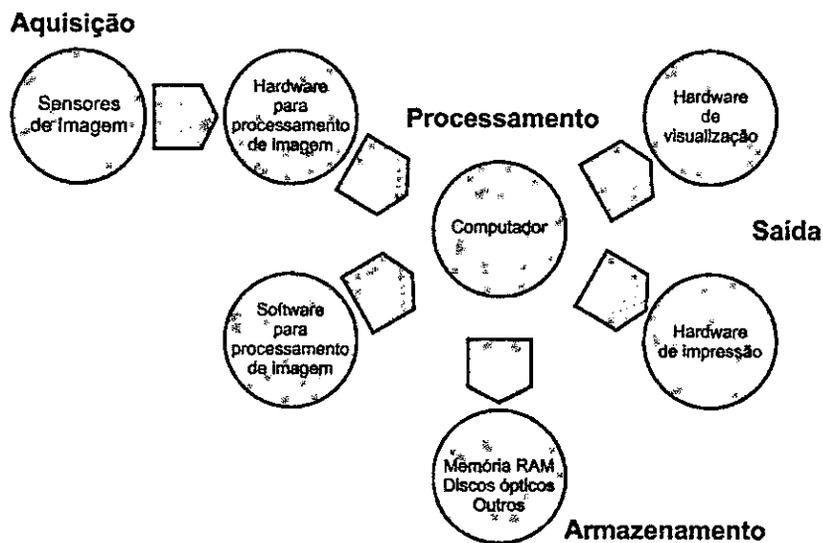
[...] dispositivos de estado sólido com a capacidade de ler o estado do ambiente para dentro e/ou fora [...]. O âmbito de um sensor é adquirir a informação sobre uma das mais das quantidades que caracterizam o ambiente no qual o sensor é exposto, a fim de medir, armazenar, processar, e para comunicar a informação.

Os sensores são expostos à luz refletida pelo alvo de interesse, o feixe de radiação eletromagnética capturada é convertido em impulsos elétricos proporcionais à intensidade luminosa incidente nos diferentes pontos da superfície do sensor e, finalmente, o digitalizador converte os impulsos elétricos em dados digitais, como ilustrado pela Figura 2 (GONZALEZ; WOODS, 2002).



**Figura 2.** Diversos tipos de interação da radiação com a matéria.  
 Fonte: Adaptado de Image Processing (Bovic, 2009).

Os elementos que compõem um sistema para aquisição de imagem devem abranger os seguintes procedimentos: aquisição, armazenamento, processamento e exibição. A Figura 3 mostra um esquema genérico desses elementos. (FILHO; NETO, 1999; JOLY, 2007).



**Figura 3.** Elementos de um sistema de processamento de imagem.  
 Fonte: (O autor, 2015).

A fase de aquisição das imagens tem como função converter uma imagem em uma representação numérica adequada para o processamento digital subsequente. Conta com dois dispositivos essenciais, um sensor e um digitalizador, que trabalham juntos para produzir sinal em forma digital (GONZALEZ; WOODS, 2002).

O armazenamento de imagens pode ser dividido em três categorias: de curta duração, em massa e arquivamento de imagens, sendo este último utilizado para recuperação futura. Armazenamento de curta duração é a forma mais simples de guardar uma imagem, fazendo uso da memória de acesso randômico (RAM) do computador. É possível utilizar também placas especializadas (*frame buffers*) que armazenam uma ou mais imagens e podem ser acessadas em alta velocidade. (GONZALEZ; WOODS, 2002).

O armazenamento em massa normalmente requer uso de discos magnéticos de no mínimo de algumas centenas de Megabytes (MB), levando-se em conta que o tempo de acesso é tão ou mais importante que a capacidade de armazenamento. Por conseguinte, o arquivamento de imagens é caracterizado por uma quantidade significativa de bytes contendo imagens cuja recuperação é esporádica. No armazenamento em massa, as fitas magnéticas estão dando lugar aos discos WORM (*Write-Only-Ready-Many*), com capacidade que pode chegar a 10 GB por disco (FILHO; NETO, 1999).

A fase de processamento envolve procedimentos normalmente expressos em forma algorítmica, com exceção das etapas de aquisição e exibição. A maioria das funções de processamento de imagens pode ser desenvolvida via software (FARIA, 2013).

Duas alternativas são típicas para as exibições no âmbito da saída do sistema de processamento de imagens. A primeira delas é a visualização de dados, que requer comumente o uso de monitores de vídeo, recebendo os dados de placas gráficas. A segunda alternativa é impressão de dados, onde se costuma utilizar diferentes dispositivos de impressão de pequeno, médio e grande porte - impressoras e/ou traçadores gráficos (*plotters*) de jato de tinta, sublimação de cera ou laser (GONZALEZ; WOODS, 2002; HANSEN, C. D., JOHNSON, 2005).

## 2.4 IMAGEM DIGITAL

Para Bovik (2009), imagem digital são imagens que foram convertidas para computador em formato binário que consistem em 0s e 1s lógicos. Para Gonzalez e Woods

(2002), uma imagem pode ser definida como uma função bidimensional, com número finito de elementos, com sua localização e valor particular. A função  $f(x, y)$ , onde  $x$  e  $y$  são coordenadas espaciais no plano, onde a amplitude de  $f$  são quaisquer pares de coordenadas  $(x, y)$  que possuem intensidade luminosa (brilho ou nível de cinza) naquele ponto.

Os computadores não são capazes de processar imagens contínuas, mas apenas *arrays* de números digitais, sendo necessário representar imagens como arranjos bidimensionais de pontos (EUSTÁQUIO; QUEIROZ; GOMES, 2001). Cada ponto forma um arranjo bidimensional ou *arrays* que são nomeados como elementos da figura, elementos de imagem, pels e pixels. Para Bovic (2009), pixel é o termo mais largamente utilizado para denotar uma unidade de imagem digital e imagem é uma matriz de valores que são normalmente dispostos no formato de linha-coluna.

Para formação de uma imagem ou um conjunto de pixels num plano que possa ser interpretado, é necessário o uso de equipamentos eletrônicos que capturem o sinal analógico do ambiente e os armazene em forma de sinal digital. Entende-se por sinal analógico: que existe um sinal contínuo (espaço/tempo) e que ele tem valores também contínuos dentro desse conjunto de possibilidades. Por sinais digitais outros dois pontos: um sinal definido como discreto em um domínio (espaço/tempo) e segundo necessita de valores discretos no conjunto de possibilidades (BOVIK, 2009).

## 2.5 PROCESSAMENTO DIGITAL DE IMAGEM (PDI)

As técnicas de Processamento Digital de Imagens têm o propósito de aprimorar informações interpretadas por seres humanos, destacando/alterando o estado inicial de uma imagem. O PDI considera o processamento das imagens na forma digital e suas transformações, como por exemplo, a fim de melhorar ou realçar suas características visuais (AZEVEDO; CONCI, 2003).

Consideram-se o PDI sob as seguintes formas de operações: operações de ponto ou a pixel individuais, operações aritméticas e operações de imagens geométricas. O primeiro são as operações de ponto, onde as interações e dependências entre pixels vizinhos não são consideradas, nem são operações que consideram múltiplos pixels simultâneos para determinar uma saída. As operações de ponto são definidas como funções de intensidade pixel (BOVIK, 2009).

A segunda categoria inclui as operações aritméticas entre imagens com as mesmas dimensões espaciais. Estas também apontam as operações no sentido de que a informação espacial não é considerada, embora a informação seja compartilhada entre as imagens em uma base pontual. Geralmente, estes têm efeitos especiais, por exemplo, para redução de ruído e alteração ou detecção de movimento (BOVIK, 2009).

A terceira classe de operações são operações de imagens geométricas. Não são definidas como funções de intensidade de imagem, em vez disso, são funções da única posição espacial. Operações desse tipo buscam alterar a aparência das imagens, alterando as coordenadas das intensidades (BOVIK, 2009).

### 2.5.1 Técnica de transformação em nível de cinza

Basicamente, a técnica de processamento por transformação em nível de cinza funciona com a realização de transformações sob o padrão de cores original da imagem, independente no nível de cinza de qualquer pixel de entrada. Os resultados adquiridos das entradas são então alimentados separadamente para dentro dos canais vermelho, verde e azul (RGB). Este método produz uma imagem de cor composta, cujo conteúdo é modulado pela natureza das funções de transformação. Há funções lineares por partes dos níveis de cinza que são utilizados para gerar as cores (GONZALEZ; WOODS, 2002).

O nível de conversão dos tons de cinza em imagem binária é determinado de acordo com o histograma RGB. Uma imagem RGB é primeiramente convertida em uma imagem em tons de cinza (WU *et al.*, 2007). O conceito de histograma também é aplicável a imagens coloridas. Neste caso, a imagem é decomposta de alguma forma (por exemplo, em seus componentes R, G e B) e para cada componente é calculado o histograma correspondente.

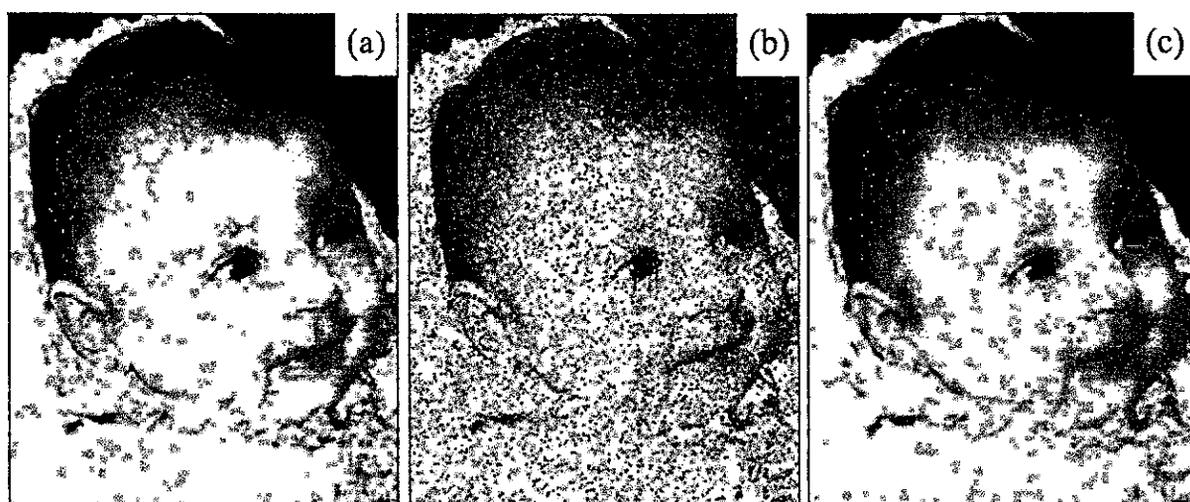
### 2.5.2 Técnica de Contraste

Uma das mais simples funções lineares de processamento de imagens é uma transformação de alongamento contraste. Imagens com baixo contraste podem resultar de má iluminação e falta de aquisição de imagem dinâmica. A ideia que circunda o contraste de alongamento é aumentar a gama dinâmica dos níveis de cinza na imagem a ser processado.

A aplicação da técnica de contraste ocorre a partir da localização de dois pontos na imagem, por exemplo, chamados  $(r_1, s_1)$  e  $(r_2, s_2)$ , para controlar a transformação. Se  $r_1 = r_2$  e  $s_1 = s_2$ , a transformação é uma função linear, que não produz alterações nos níveis de cinza. Se  $r_1 = r_2, s_1 = 0$  e  $s_2 = L - 1$ , sendo  $L$  os níveis de entrada/saída de cinza, identifica-se a transformação de uma função de limiar (*thresholding function*) que cria uma imagem binária. Os valores intermediários de  $(r_1, s_1)$  e  $(r_2, s_2)$  produzem vários graus de dispersão nos níveis de cinza da imagem de saída, afetando assim, o contraste. Esta condição preserva a ordem dos níveis de cinza, evitando assim a criação de artefatos de intensidade na imagem processada (GONZALEZ; WOODS, 2002).

### 2.5.3 Técnica de Suavização (Filtro da mediana)

Na técnica de suavização, o nível de cinza do pixel central da janela é substituído pela mediana dos pixels situados em sua vizinhança. Este método apresenta desempenho particularmente bom em situações nas quais a imagem é contaminada por ruído impulsivo (sal-e-pimenta), conforme ilustrado na Figura 4.



**Figura 4.** (a) Imagem original; (b) Imagem contaminada por ruído impulsivo (sal e pimenta); (c) Resultado da filtragem pelo filtro mediana com máscara 3x3.

Fonte: (Filho; Neto, 1999).

A mediana  $m$  de um conjunto de  $n$  elementos é o valor tal que metade dos  $n$  elementos do conjunto situem-se abaixo de  $m$  e a outra metade acima de  $m$ . Quando  $n$  é ímpar, a mediana é o próprio elemento central do conjunto ordenado. Nos casos em que  $n$  é par, a mediana é calculada pela média aritmética dos dois elementos mais próximos do centro.

A ordenação (*sorting*) constitui uma etapa de tempo de processamento relativamente alto, apesar de diversos métodos eficientes existentes na literatura (FILHO; NETO, 1999).

#### 2.5.4 Técnica de Segmentação (Limiarização)

Segundo Gonzalez e Woods (2002), as técnicas de extração de informação a partir de imagens pertencem à área do processamento referida como análise de imagens, que, para ser executada, tem como passo inicial a realização de uma segmentação.

A técnica de segmentação de imagens tem basicamente dois objetivos: (1) decompor a imagem em partes para posterior análise; (2) realizar uma mudança de representação (SHAPIRO, L. G.; STOCKMAN, 2001). O resultado final esperado de um processo de segmentação é um número finito de regiões homogêneas que individualizam as diferentes regiões contidas numa imagem. Sendo assim, a imagem seria formada por um conjunto de regiões conectadas pelas suas bordas e que não se sobrepõem, de tal forma que cada pixel da imagem pertence unicamente a uma determinada região (ACHARYA; RAY, 2005).

A limiarização é uma das abordagens mais importantes para a segmentação (GONZALEZ; WOODS, 2002). O processo baseia-se na análise da distribuição de probabilidade de ocorrência dos níveis de cinza em uma imagem, onde as faixas de intensidade correspondem às bandas do histograma. Nessa situação o histograma apresenta dois picos separados por um vale entre eles, sendo assim, esses picos podem representar duas regiões distintas, como por exemplo, um fundo e um objeto. Seguindo o mesmo raciocínio, se o histograma de uma imagem for tri-modal poderíamos então obter a representação de três regiões distintas, como dois objetos e um fundo.

## CAPÍTULO 3

### REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são uma abstração do neurônio biológico, onde a ideia do neurônio artificial não é replicar a operação de um sistema biológico, mas sim fazer uso do que é conhecimento sobre a funcionalidade da rede biológica para resolver problemas complexos (BASHEER; HAJMEER, 2000).

Uma RNA pode ser definida também como sistemas paralelos e distribuídos baseados no sistema neurológico, apresentando estruturas dispostas em uma ou mais camadas coesas por um grande número de conexões (neurônios) associadas a pesos, os quais armazenam o conhecimento e servem para ponderar as entradas recebidas por cada neurônio. (ATA, 2015; BORGES, 2013). Uma RNA possui a capacidade de aquisição e manutenção do conhecimento (baseado em informação) e podem ser definidas como um conjunto de unidades de processamento (SILVA; SPATTI; FLAUZINO, 2010).

#### 3.1 HISTÓRICO

A primeira publicação relacionada à neurocomputação data de 1943, por intermédio do trabalho conjunto do psicólogo e neurofisiologista Warren McCulloch e o matemático Walter Pitts, onde apresentaram uma modelagem matemática de redes lógicas de neurônios artificiais. (SCHIAVONI, 2010; SILVA; SPATTI; FLAUZINO, 2010).

Mesmo com as pesquisas de McCulloch e Pitts iniciadas em 1943, o primeiro método de treinamento para redes neurais artificiais foi proposto por Donald Hebb em 1949. O método conhecido como regra geral de Hebb ou regra de aprendizado de Hebb descreve como as mudanças de pesos sinápticos controlam a maneira como os neurônios podem excitar um ao outro (KURISCAK *et al.*, 2015; SILVA; SPATTI; FLAUZINO, 2010).

Nos anos 50, Frank Rosenblatt desenvolveu uma estrutura de rede neural chamada *Perceptron*. A rede neural *Perceptron* despertou interesse pela capacidade de “aprendizagem” para classificar certos padrões. Logo após, em 1960, Bernard Widrow e Marcian Hoff publicaram um artigo intitulado “Adaptative Switching Circuits”, onde apresentaram um dispositivo chamado *Adaline (ADaptative LINear Element)*, uma outra implementação de

rede neural para classificação linear (RUSSELL C. EBERHART; SHI, 2007; SILVA; SPATTI; FLAUZINO, 2010).

Com as pesquisas iniciadas na área, muitos outros pesquisadores se interessaram na possibilidade de máquinas inteligentes. Contudo, em 1969 teve-se a “era negra” da inteligência computacional, onde Marvin Minsky e Seymour Papert apresentaram a comunidade da neurocomputação em seu livro “*Perceptrons - an introduction to computational geometry*”, à eficaz funcionalidade da aplicação da rede *Perceptron*, mas também a limitação de redes neurais, constituídas por apenas uma única camada (Rede *Perceptron* e *Adaline*) em aprender a relação entre as entradas e saídas de relações lógicas, o que desmontou em uma redução do número de pesquisas na área (RUSSELL C. EBERHART; SHI, 2007; SILVA; SPATTI; FLAUZINO, 2010).

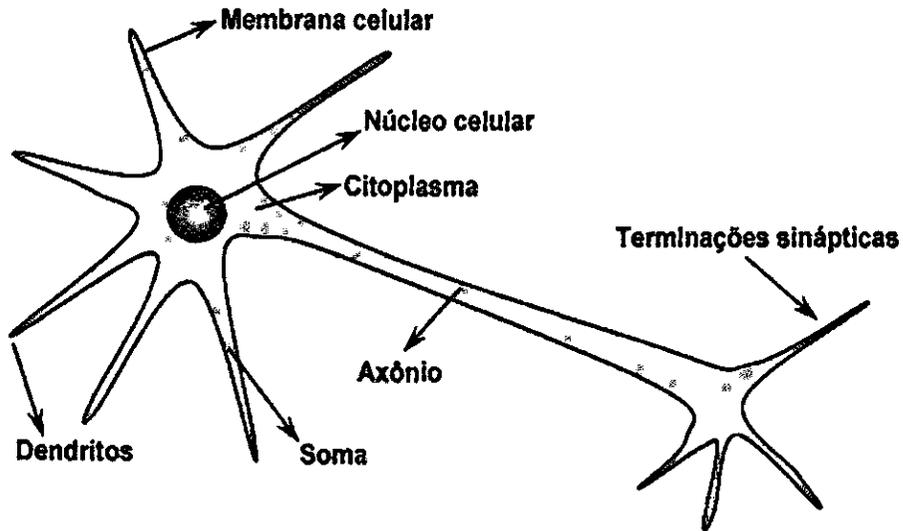
O fim da “era negra” da neurocomputação e a retomada das pesquisas ocorreu por volta de 1982 a 1986 fato deve-se ao desenvolvimento dos computadores e das tecnologias, que proporcionaram maior capacidade de processamento, assim como as novas descobertas sobre o sistema nervoso e os novos modelos de RNAs (BASHEER; HAJMEER, 2000; KURISCAK *et al.*, 2015). O retorno trouxe novas abordagens e métodos como, por exemplo, em 1986, David Rumelhart, Geoffrey Hinton e Ronald Williams propuseram o algoritmo *Backpropagation*, que realiza uma realimentação dos pesos de redes com mais de uma camada, o que solucionava as dificuldades da rede em aprender relações lógicas, como o ou-exclusivo ( $X_{OR}$ ). Deste ponto em diante, as pesquisas sobre Redes Neurais estão sendo grandemente exploradas nas áreas da Ciência da Computação (ENGELBRECHT, 2007; RUSSELL C. EBERHART; SHI, 2007; SILVA; SPATTI; FLAUZINO, 2010).

### 3.2 NEURÔNIO BIOLÓGICO X NEURÔNIO ARTIFICIAL

O cérebro é um complexo computador não linear e paralelo, atrelado a ele está à capacidade de reconhecer padrões, percepção, capacidade de aprender, memorizar e ainda generalizar, características que incitaram o desenvolvimento de pesquisas na modelagem algorítmica de sistemas neurais biológicos (ENGELBRECHT, 2007).

O processamento das informações no cérebro humano é regido por processadores biológicos que operam em paralelo, o neurônio. Seu papel se resume em conduzir impulsos (estímulos elétricos advindos de reações físico-químicas) (SILVA; SPATTI; FLAUZINO,

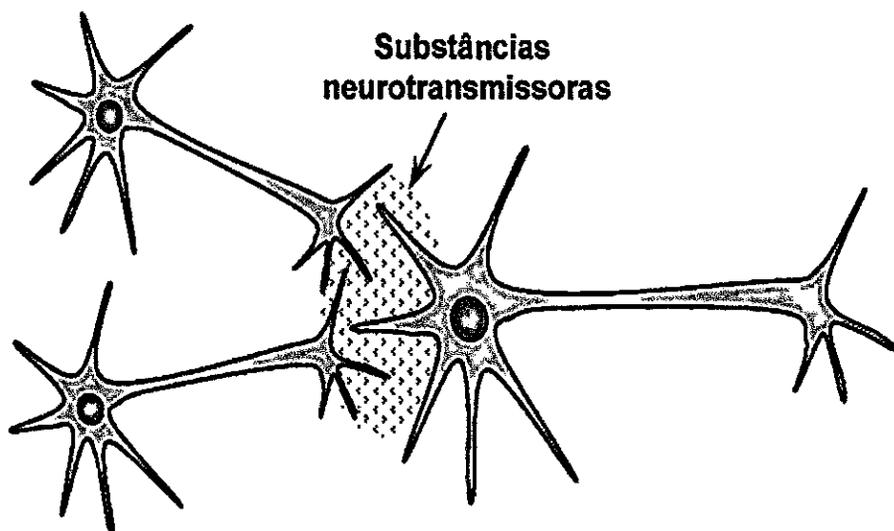
2010). O neurônio pode ser dividido em três partes principais: dendritos, corpo celular (também conhecido como soma) e axônio (Figura 5) (SILVA; SPATTI; FLAUZINO, 2010).



**Figura 5.** Neurônio biológico.  
Fonte: (SILVA; SPATTI; FLAUZINO, 2010).

Os dendritos são constituídos por vários finos prolongamentos que formam a árvore dendrital. Sua função consiste em captar, de forma contínua, os estímulos vindos de diversos outros neurônios (conectores) ou do próprio meio externo, onde os mesmos podem estar em contato (neurônios sensitivos) e repassam para o corpo celular (SILVA; SPATTI; FLAUZINO, 2010).

O corpo celular processa as informações advindas dos dendritos a fim de produzir um potencial de ativação que indicará se o neurônio poderá disparar um impulso elétrico ao longo do seu axônio. Os impulsos elétricos recebidos são conduzidos para outros neurônios conectores ou para aqueles que se conectam diretamente com o tecido muscular (neurônios efetadores) por meio das suas ramificações, chamadas terminações sinápticas (Figura 6) (BASHEER; HAJMEER, 2000; SILVA; SPATTI; FLAUZINO, 2010).



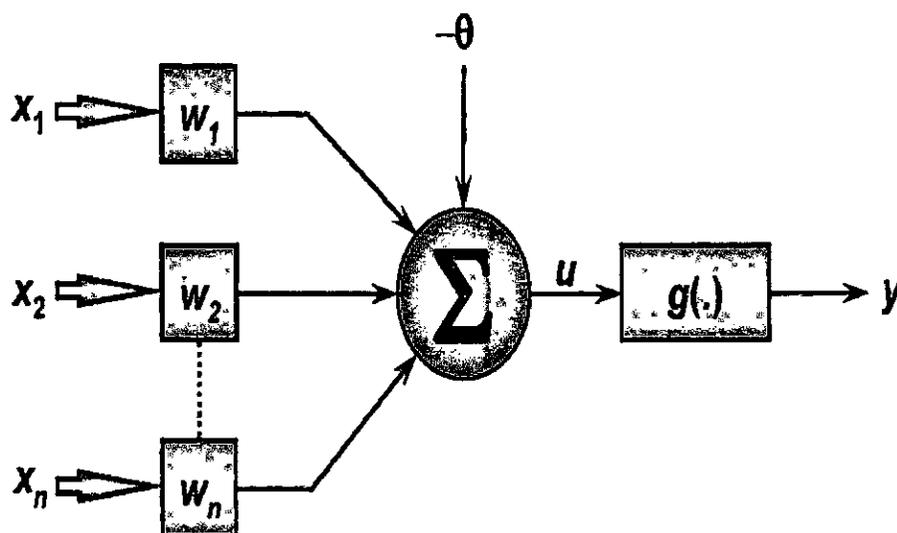
**Figura 6.** Conexões sinápticas entre neurônios.

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

Analogamente ao neurônio biológico (NB), o neurônio artificial (NA) foi inspirado a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios (SILVA; SPATTI; FLAUZINO, 2010). Cada NA recebe os sinais vindos do ambiente (entrada) ou de outro NA, reúne esses sinais e quando acionado, transmite um sinal para todos os NAs relacionados.

A Figura 7 ilustra um modelo de neurônio mais simples proposto por McCulloch & Pitts (1943), apresentando as principais características de uma rede neural biológica, isto é, o paralelismo e a alta conectividade. O neurônio artificial é composto por um conjunto de sinais de entrada  $\{X_1, X_2, \dots, X_n\}$ , que simulam os impulsos elétricos que chegam ao neurônio biológico. Os pesos sinápticos  $\{W_1, W_2, \dots, W_n\}$  ponderam cada uma das variáveis de entrada da rede, por operação de multiplicação entre eles. Os resultados equivalem às reações químicas que ocorrem no corpo celular (ENGELBRECHT, 2007; SILVA; SPATTI; FLAUZINO, 2010).

Cada resultado do produto das entradas pelos pesos é somado com o limiar de ativação ( $-\theta$ ), tendo como resultado o potencial de ativação ( $u$ ), na forma biológica equivale a um potencial excitatório ou inibitório. A função de ativação ( $g(u)$ ), carrega o valor advindo de  $u$  e tem como meta limitar a saída do neurônio dentro de um intervalo de valores, tendo como resposta um valor de saída da rede ( $y$ ) (ENGELBRECHT, 2007; SILVA; SPATTI; FLAUZINO, 2010).



**Figura 7.** Neurônio artificial.  
 Fonte: (SILVA; SPATTI; FLAUZINO, 2010).

As funções de ativação ( $g(u)$ ) podem ser divididas em dois grupos. Funções parcialmente diferenciáveis que possuem pontos cujas derivadas de primeira ordem são inexistentes como a função degrau, degrau bipolar e rampa simétrica. As funções totalmente diferenciáveis, compõem a segunda categoria cujas as derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de definição. As funções desse grupo empregadas às redes neurais artificiais são a função logística, a tangente hiperbólica, a gaussiana e a função linear (SANTOS, 2013; SILVA; SPATTI; FLAUZINO, 2010).

### 3.3 ARQUITETURAS DE REDES NEURAIS ARTIFICIAIS

Uma rede neural pode ser dividida em três partes, denominadas camadas. A camada de entrada é responsável pelo recebimento das informações (dados), sinais, características ou medições que são normalmente normalizadas em relação às faixas de variação (SILVA; SPATTI; FLAUZINO, 2010).

A segunda parte de uma RNA é formada por camadas intermediárias ou ocultas, compostas por neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido. A terceira parte também constituída por neurônios, é a camada de saída responsável pela produção e apresentação dos resultados finais da rede, resultados estes vindos das camadas escondidas ou diretamente da camada de entrada (SILVA; SPATTI; FLAUZINO, 2010).

As principais arquiteturas de redes neurais artificiais levando em consideração à disposição dos neurônios, a forma de interligação entre eles e a constituição de suas camadas, são: redes *feedforward* de camada simples e de camadas múltiplas além das redes recorrentes (SILVA; SPATTI; FLAUZINO, 2010).

As redes *feedforward* de camada simples apresentam arquitetura acíclica onde as informações seguem numa única direção, composta por uma camada de entrada e uma única camada de neurônios que é a própria saída (Figura 8a). São exemplos de arquitetura de camadas simples as redes *Perceptron* e *Adaline*. As redes *feedforward* de camadas múltiplas são constituídas pela presença de uma ou mais camadas escondidas de neurônios (Figura 8b). Exemplos desta categoria são as redes *Perceptron* multicamadas (MLP) e as redes de base radial (*Radial Bases Function* – RBF). As redes recorrentes possuem uma arquitetura que permite a realimentação entre as saídas dos neurônios como sinais de entrada em outros neurônios (Figura 8c). Como exemplo deste modelo estão os modelos de *Hopfield* e as redes MLP com realimentação (SILVA; SPATTI; FLAUZINO, 2010; SILVA, 2005).

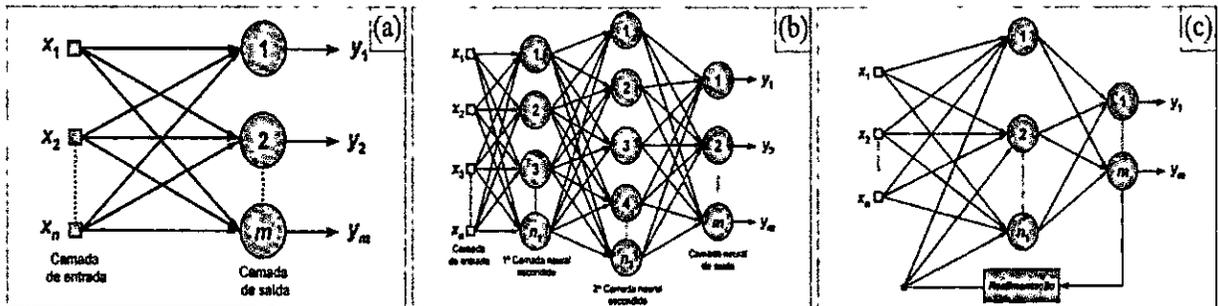


Figura 8. Arquiteturas (a) Rede *feedforward* de camada simples, (b) Rede *feedforward* multicamadas e (c) Rede recorrente.

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

### 3.4 TREINAMENTO DE UMA RNA

Uma das características mais importantes das RNAs é a sua capacidade de aprendizado a partir da apresentação de amostras (exemplos), que descrevem o comportamento do sistema, sendo que, após a rede ter aprendido o relacionamento entre as entradas e saídas, esta é capaz de generalizar novas amostras (SCHIAVONI, 2010).

A etapa de aprendizado de uma rede neural consiste na aplicação de passos ordenados que sejam necessários para sintonização dos pesos sinápticos e limiares de seus neurônios, os quais guardam ao final do processo, o conhecimento adquirido do ambiente

externo. O conjunto desses passos para treinamento de uma rede é chamado de algoritmo de aprendizagem (SCHIAVONI, 2010; SILVA; SPATTI; FLAUZINO, 2010).

O conceito de aprendizado está relacionado com a melhoria do desempenho da rede segundo algum critério preestabelecido. Para que seja alcançada a melhoria, as amostras disponíveis para o treinamento são divididas em dois subconjuntos, um subconjunto de treinamento e subconjunto de teste. A partir da quantidade total de amostras presentes no sistema, utiliza-se comumente cerca de 60% a 90% das amostras totais, selecionadas aleatoriamente, para compor o subconjunto de treinamento. Para o subconjunto de teste, a composição fica entre 10% e 40% do conjunto total de amostras para verificar se os aspectos referentes à generalização estão aceitáveis (SILVA; SPATTI; FLAUZINO, 2010).

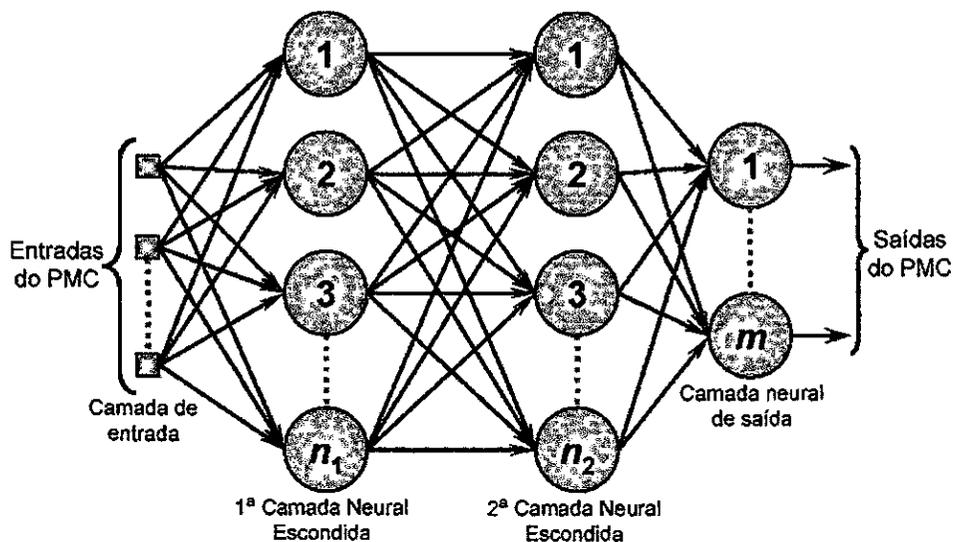
#### 3.4.1 Treinamento supervisionado

O treinamento supervisionado consiste fornecer para a rede uma tabela de entrada/saída, caracterizando qual é o valor adequado ou inadequado para cada entrada apresentada e a partir dessas informações que as estruturas neurais formularão suas “hipóteses” sobre o que deve ser aprendido (SANTOS, 2013).

Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada com o padrão de saída da tabela de dados e os pesos sinápticos e limiares são ajustados continuamente, aplicando ações comparativas, executadas pelo próprio algoritmo de aprendizagem. Estas supervisionam a defasagem entre as respostas produzidas pela rede em relação àquelas desejadas, onde, uma vez encontrada diferenças, são aplicados os procedimentos de ajustes (SANTOS, 2013; SILVA; SPATTI; FLAUZINO, 2010).

### 3.5 REDES *PERCEPTRON* MULTICAMADAS

As redes *Perceptron* de múltiplas camadas (MLP) são caracterizadas pela presença de uma camada de entrada, uma ou mais camadas escondidas e a camada de saída (Figura 9). Cada camada tem um número de unidades de processamento e cada unidade é fortemente interconectada com os pesos das camadas posteriores (YILMAZ; KAYNAR, 2011).



**Figura 9.** Arquitetura da Rede *Perceptron* Multicamadas.

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

A propagação dos sinais de entradas da rede MLP obedece à arquitetura *feedforward*, onde independentemente da presença de camadas escondidas é sempre realizada num único sentido, da camada de entrada em direção à camada de saída. O processo de funcionamento ocorre a partir dos estímulos ou sinais apresentados à rede na camada de entrada. As camadas intermediárias, por sua vez, extraem a maioria das informações referentes ao seu comportamento e as codificam e realizam ajustes dos pesos sinápticos e limiares de seus neurônios. Finalmente, os neurônios da camada de saída recebem os estímulos da última camada intermediária, produzindo um padrão de resposta mediante o processo de treinamento supervisionado (SILVA; SPATTI; FLAUZINO, 2010).

O processo de treinamento da rede MLP utiliza do algoritmo *backpropagation*, conhecido também como regra Delta generalizado, que se baseia na heurística de aprendizado por correção de erro. O erro é retro propagado da camada de saída para as intermediárias da RNA (SCHIAVONI, 2010).

O algoritmo segue duas fases, a primeira a ser aplicada é chamada de “propagação adiante” (*forward*), na qual os sinais  $\{X_1, X_2, \dots, X_n\}$  de uma amostra do conjunto de treinamento são inseridos nas entradas da rede e são propagadas camada a camada até a produção das saídas. Essa primeira fase busca obter os valores dos pesos sinápticos e limiares de cada neurônio. Os resultados que chegaram à saída são usados para comparar com as saídas desejadas, no processo de aprendizado supervisionado (SILVA; SPATTI; FLAUZINO, 2010).

A segunda fase chamada de “propagação reversa” (*backward*) é realizada em função dos erros encontrados, realizando ajustes dos pesos sinápticos e limiares de todos os neurônios da rede. De forma simples, as duas fases (*forward* e *backward*) fazem com que os pesos e limiares dos neurônios se ajustem automaticamente, garantindo que a resposta obtida aproxime-se mais do padrão de resposta desejada (SCHIAVONI, 2010; SILVA; SPATTI; FLAUZINO, 2010).

Uma das formas de potencializar o desempenho do treinamento da MLP é utilizar o método de validação cruzada (*cross-validation*). O método proporciona avaliar a aptidão de cada uma das camadas, quando aplicadas a um conjunto de dados diferentes daqueles usados no ajuste de seus parâmetros internos. Em suma, usa-se do mesmo conjunto de treinamento para ajustar todas as topologias candidatas que foram geradas, fazendo uso daquela que possuir melhor topologia e a menor quantidade de neurônios nas camadas escondidas (TARALLO, 2007).

## CAPÍTULO 4

### MATERIAIS E MÉTODOS

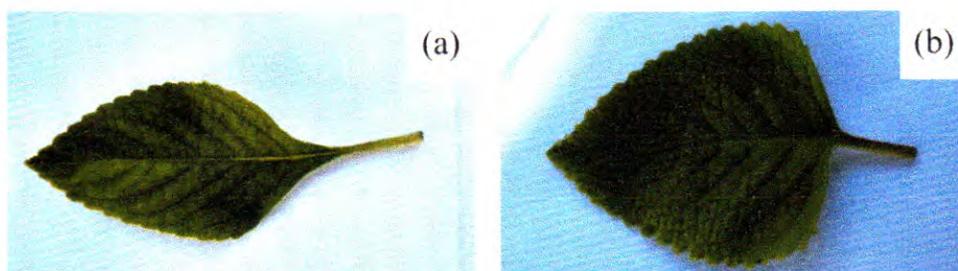
O uso de processamento de imagens e redes neurais artificiais para automatizar o processo de reconhecimento de características em imagens. Aplicou-se a técnica de Wu e colaboradores (2007), que utiliza descritores de forma com rede neural probabilística para classificação de folhas, e Kadir e colaboradores (2011), que aplica técnicas de processamento de imagens para extrair a forma, cor e textura. Agregando aos métodos abordados, utilizou-se da forma da folha (limbo, pecíolo) para realizar a identificação de novas características, apontando o pecíolo como componente de validação.

#### 4.1 AMOSTRAS DAS FOLHAS DA FAMÍLIA *PLECTRANTHUS*

Realizou-se uma visita técnica ao Projeto de Socialização de Plantas Mediciniais Farmácia Viva localizado no município de Parnaíba no estado do Piauí. O horto da Farmácia Viva conta com 16 espécies de plantas medicinais, das quais duas espécies são semelhantes por pertencerem à mesma família genética, Malva (*Plectranthus barbatus*) uso no tratamento de gastrite, azia, ressaca, mal estar gástrico, estimulante da digestão e do apetite; e o Boldo (*Plectranthus amboinicus*) erva medicinal com uso indicado como expectorante, para inflamações na boca e garganta. Inicialmente, foram coletadas folhas adultas de cada uma das espécies, onde foram verificadas suas características morfológicas.

As características morfológicas perceptíveis às folhas do gênero *Plectranthus amboinicus* (Figura 10a) são: apresentam folha completa (presença de limbo, pecíolo e bainha), são palminérveas (nervação que parte de um mesmo ponto), forma elítica (mais larga no meio, comprimento duas vezes a largura) com bordas crenadas, possui ápice agudo e base acunhada.

A espécie *Plectranthus barbatus* (Figura 10b) possui folha completa, palminérveas, forma deltoide (forma de delta, triangular) com bordas crenadas, ápice agudo e base hastada. As duas espécies apresentam cheiro característico.



**Figura 10.** (a) Boldo (*Plectranthus amboinicus*); (b) Malva (*Plectranthus barbatus*).

Fonte: O autor, 2015.

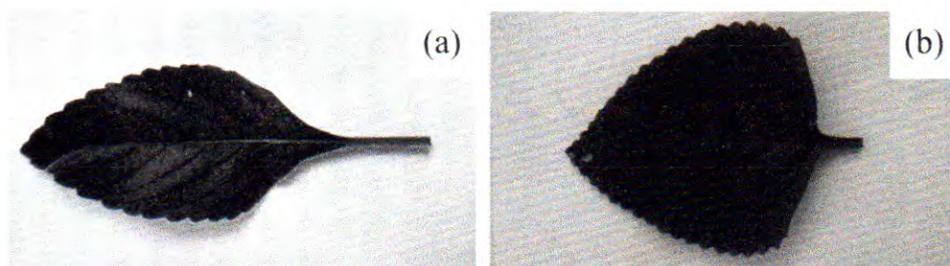
## 4.2 AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS

Com as folhas coletadas de cada espécie, foram fotografadas por três aparelhos celulares, Motorola® Defy MB525 com resolução de 5.0 MegaPixels, SONY® Xperia L e Motorola® MotoG g2 com resolução de 8.0 MegaPixels. O propósito das diferentes resoluções foi obter imagens com maior e menor grau de detalhes, fazendo com que as técnicas de PDI gerem resultados diferentes para a mesma fotografia. As amostras foram capturadas três vezes, obtendo um total de 30 imagens com resoluções de 2592x1944, 3264x2448 e 3264x1836 pixels.

Para extração de características das folhas, utilizou-se o software ImageJ 1.46r (FERREIRA; RASBAND, 2012), software de domínio público desenvolvido em Java para processamento e análise de imagens. As imagens foram importadas para o aplicativo, onde suas matrizes de cores padrões foram alteradas, RGB (*Red, Green, Blue*) para escala de cinza 8-bits (Figura 11), utilizando a Fórmula I:

$$(I) \textit{gray} = 0.299 \times R + 0.587 \times G + 0.114 \times B$$

A fórmula utilizada pelo software resulta na aplicação da técnica de escala de cinza, onde  $0.299 \times R$ ,  $0.587 \times G$  e  $0.114 \times B$  correspondem ao produto dos tons de cinza de cada componente de cor pela cor encontradas na imagem, obedecendo o padrão RGB.

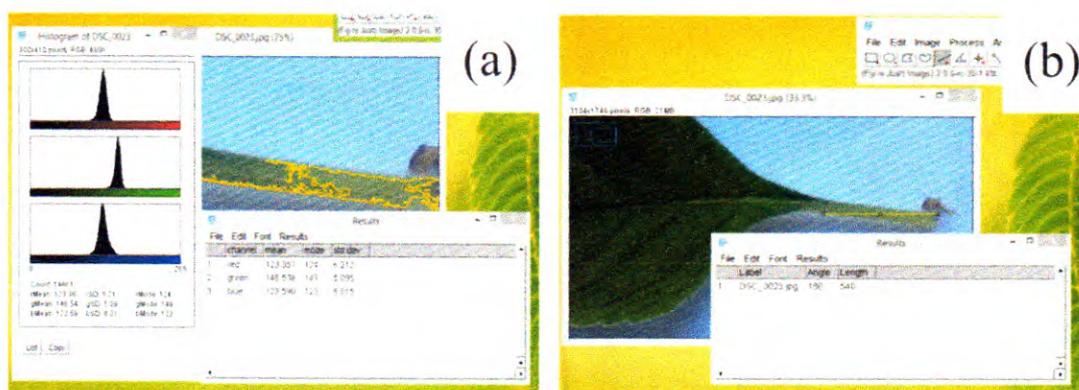


**Figura 11:** Folha de Boldo à esquerda e Malva à direita, escala de cinza.

Fonte: O autor, 2015.

Tendo-se obtido a imagem em escala de cinza, utilizou-se da função de binarização, que se converte a imagem em escala de cinza em dois subconjuntos de pixels, sendo um conjunto que define o primeiro plano (pixels pretos) e outro para o fundo (pixels brancos). O método foi utilizado para extrair o conjunto de pixels de primeiro plano da imagem, que identificam a forma da folha e que posteriormente, usou-se da ferramenta de rastreamento (*wand*) com a configuração de tolerância de 100 pixels (*default*). Essa configuração seleciona uma área de valores de pixels que estão entre a faixa de valores da seleção, permitindo uma seleção de cores mais próximas e com a função medir (*measure*), presente no menu Analisar (*Analyze*) da ferramenta. Obteve-se, por comando procedimentais, informações sobre a folha como um todo, contendo a área, perímetro, comprimento e largura.

Para caracterização do pecíolo, primeiro utilizou-se a ferramenta de rastreamento na parte da imagem original que corresponde ao pecíolo, com a configuração de tolerância de 5 pixels, permitindo-nos traçar uma seleção da faixa de cores mais próximas. Com a seleção, foi utilizado a ferramenta de análise de histograma (*color histogram*), que disponibilizou o conjunto dos valores RGB mais encontrados dentro da seleção (Figura 12a). Com a ferramenta linha (*straight*) de maneira manual, traçou-se uma linha para corresponder ao comprimento e com a função medir (*measure*), presente no menu Analisar (*Analyze*) do software, resgatou-se esse resultado (Figura 12b).



**Figura 12:** (a) Área selecionada para extração do conjunto de cores no pecíolo; (b) Ferramenta *straight* para indicar o comprimento.

Fonte: (O autor, 2015).

Realizados todos os processos sobre as imagens, criou-se a Tabela 1 com os dados relacionados às características morfológicas das folhas. Com base nesta tabela, produziu-se

um novo arquivo de texto contendo apenas os valores da tabela, que posteriormente foi utilizado como base de dados de entradas para a Rede Neural MLP.

**Tabela 1.** Dados adquiridos com o processamento de imagens

Nome da Amostra	Área (Pixel)	Perímetro (Pixel)	LarguraT (Pixel)	AlturaT (Pixel)	R	G	B	ComprimentoP (Pixel)
<b>Boldo_A.jpg</b>	1413423	6.344.779	2290	1104	127	145	92	564.125
<b>Boldo_A.jpg</b>	1669691	8.745.818	2549	1148	124	133	98	529.030
<b>Boldo_A.jpg</b>	1649294	10.291.583	2328	1224	124	150	122	620.001
<b>Boldo_A.jpg</b>	1595945	9.986.277	2507	1151	103	134	84	552.008
<b>Boldo_A.jpg</b>	1647045	8.550.823	2513	1226	125	135	88	632.000
<b>Malva_A.jpg</b>	1819913	7.030.623	1954	1566	102	100	103	186.000
<b>Malva_A.jpg</b>	2147097	7.915.005	2206	1639	107	96	111	417.011
<b>Malva_A.jpg</b>	2088635	9.527.714	2294	1632	134	112	119	454.004
<b>Malva_A.jpg</b>	2096899	8.470.541	2392	1579	114	105	87	324.000
<b>Malva_A.jpg</b>	1771073	7.577.109	1908	1554	115	115	104	492.000
<b>Boldo_D.jpg</b>	1511506	8.246.544	2793	1112	136	149	63	490.502
<b>Boldo_D.jpg</b>	1593823	7.677.199	2592	1138	171	191	141	495.000
<b>Boldo_D.jpg</b>	1537925	7.264.859	2407	1122	201	218	163	555.008
<b>Boldo_D.jpg</b>	1699622	8.764.673	2873	1114	98	119	38	570.000
<b>Boldo_D.jpg</b>	1421250	10.381.424	2760	1128	135	133	53	687.000
<b>Malva_D.jpg</b>	2052537	7.556.998	2071	1663	77	55	37	210.000
<b>Malva_D.jpg</b>	2489168	9.706.349	2380	1750	107	96	111	408.000
<b>Malva_D.jpg</b>	2274492	12.580.900	2380	1704	80	63	44	501.000
<b>Malva_D.jpg</b>	2387863	9.713.312	2584	1703	69	65	30	471.000
<b>Malva_D.jpg</b>	2200810	8.666.742	2179	1735	93	74	34	372.000
<b>Boldo_R.jpg</b>	1038778	7.324.375	2198	932	126	133	59	430.000
<b>Boldo_R.jpg</b>	1044610	9.297.833	2238	897	137	137	69	413.335
<b>Boldo_R.jpg</b>	1150591	9.397.255	2068	1062	146	144	81	502.668
<b>Boldo_R.jpg</b>	956916	7.082.836	2198	848	129	131	57	426.669
<b>Boldo_R.jpg</b>	907477	6.963.380	1958	904	109	116	73	516.000
<b>Malva_R.jpg</b>	1262599	6.507.653	1631	1292	69	66	66	222.002
<b>Malva_R.jpg</b>	1411355	7.849.710	1840	1334	64	62	65	369.000
<b>Malva_R.jpg</b>	1462812	8.525.790	1962	1361	106	94	61	418.669
<b>Malva_R.jpg</b>	1493950	10.444.916	2084	1376	111	102	60	477.333
<b>Malva_R.jpg</b>	1327456	8.503.344	1711	1363	68	69	38	337.000

#### 4.3 REDE NEURAL MULTILAYER PERCEPTRON (MLP)

Para implementação da rede neural MLP utilizou-se o software MatLab<sup>®</sup> na versão R2013a (8.1.0.604). O MatLab<sup>®</sup> é uma de linguagem de alto nível e um ambiente de desenvolvimento para computação matemática, visualização e programação, que possibilitou o desenvolvimento do código na plataforma.

Foi desenvolvida uma rede neural do tipo *Multilayer Perceptron*, que utilizou como parâmetros de entrada o conjunto de dados numéricos (Área, Perímetro, LarguraT,

AlturaT, R, G, B e ComprimentoP) das amostras (Tabela 1). Com base no conjunto de dados utilizou-se 60%, 20% e 20% dos dados para treinamento, validação e teste, todos selecionados aleatoriamente (Tabela 2).

**Tabela 2.** Conjunto de dados de treinamento, validação e teste.

	Nº de Experimentos	%
<b>Treinamento</b>	18	60
<b>Validação</b>	6	20
<b>Teste</b>	6	20
<b>Total</b>	<b>30</b>	<b>100</b>

A RNA foi configurada para receber oito entradas na primeira camada, todas normalizadas entre 0,1 e 0,9. Duas camadas neurais escondidas e uma camada de saída. Para definir a quantidade de neurônios nas camadas escondidas, valeu-se do teorema de Kolmogorov, onde para um conjunto de P entradas, devemos utilizar de  $2P+1$  neurônios na camada escondida, optando assim por adequar até o dobro de neurônios recomendados. A primeira camada escondida configurada para variar de 2 (dois) até 16 (dezesesseis) neurônios e a segunda de 0 (zero) até 8 (oito) neurônios.

## CAPÍTULO 5

### RESULTADOS E DISCUSSÃO

Os testes realizados sobre processamento digital de imagem para reconhecimento e classificação das folhas das espécies *Plectranthus amboinicus* (boldo) e *Plectranthus barbatus* (malva), mostraram-se eficientes na obtenção das métricas da área, perímetro, largura, altura e cores.

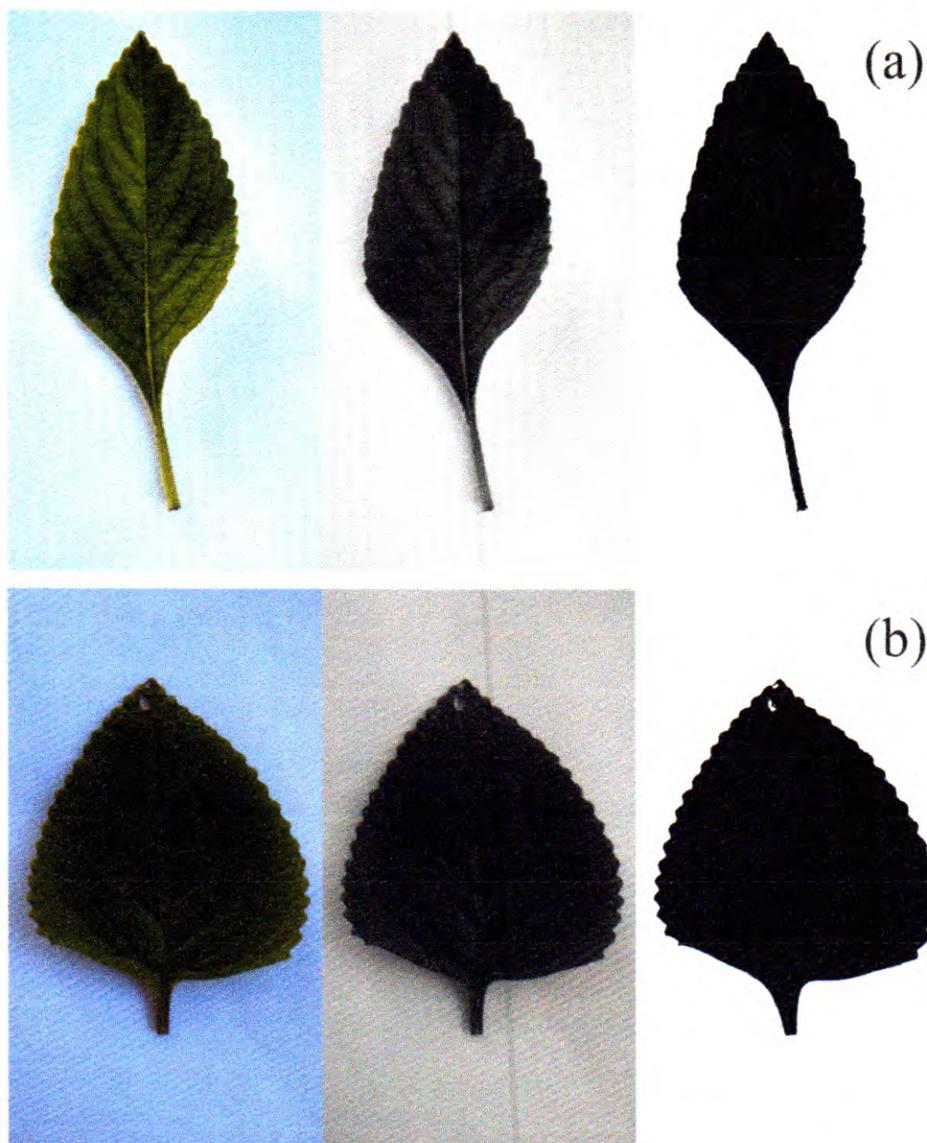
O pressuposto de que as mesmas amostras fotografadas por dispositivos diferentes garantiriam parâmetros distintos foi confirmada, quando se observou que dispositivos com mesma resolução de câmera produziram imagens com matrizes de pixels distintos (Tabela 3), contribuindo assim, com enriquecimento do conjunto de dados formulados para cada uma das amostras utilizadas.

**Tabela 3.** Relação entre a resolução e a matriz de pixels dos dispositivos utilizados para realizar a captura das imagens.

Dispositivo	Resolução	Matriz de Pixels
Motorola® Defy MB525	5 Megapixel	2592 x 1456
SONY® Xperia L	8 Megapixel	1746 x 3104
Motorola® MotoG g2	8 Megapixel	1836 x 3264

A técnica de conversão em escala de cinza em conjunto com a binarização (*Thresholding*) fornecidas pela ferramenta ImageJ 1.46r, proporcionou a formação de imagens em preto e branco, sendo que os pixels pretos corresponderam ao objeto folha presente na imagem. As imagens foram tiradas sem que houvesse controle de iluminação ou utilização prévia de filtros. Observou-se que após o uso das técnicas, as sombras implicaram em acréscimos sobre o objeto folha e a iluminação, uma redução do conjunto de pixels (Figura 13a/b).

O resultado do processamento, com influência da iluminação, não impediu a extração dos dados requeridos para o conjunto de entradas da rede neural. Conclui-se a partir disso que os métodos de escala de cinza e binarização, possibilitam especificar o objeto folha dentro do quadro de pixels (Figura 13).



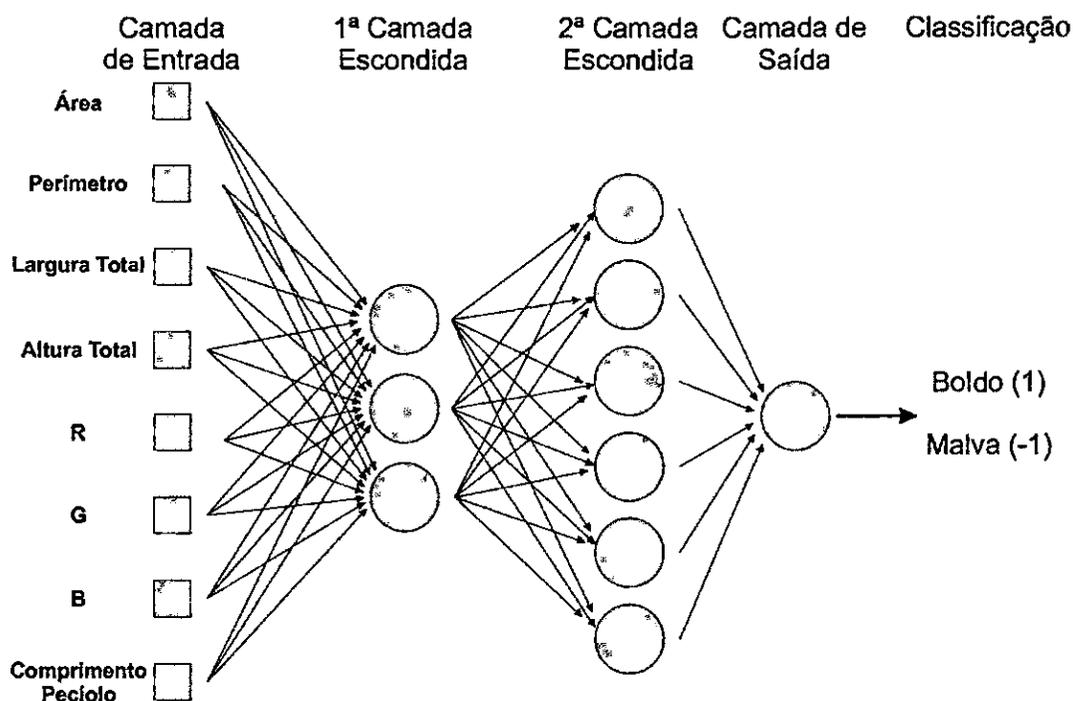
**Figura 13.** Técnicas de escala de cinza e binarização: (a) Exemplo do processamento da imagem de Boldo, (b) Exemplo do processamento da imagem da Malva

**Fonte:** (O autor, 2015).

A extração das cores com a ferramenta de rastreamento, em conjunto com a análise do histograma de cores, mostrou-se muito eficiente por apresentar a média das cores encontradas na seleção, e o valor correspondente RGB. Uma dificuldade nessa etapa foi encontrar um valor de precisão para o rastreamento, que englobasse apenas o pecíolo e a maior área possível.

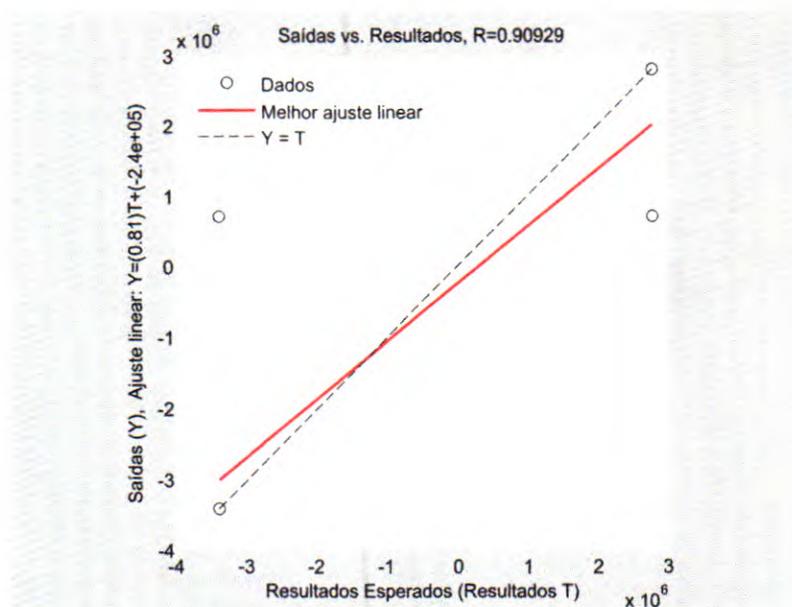
Com a manipulação da ferramenta *Straight*, foi obtido como resultado, a identificação do comprimento do pecíolo. A relevância do uso da função está na capacidade de diferenciação métrica do pecíolo das duas espécies da família *Plectranthus*.

Por meio dos testes realizados sobre os dados do processamento das imagens, a RNA detectada com o maior índice de acerto, ou seja, a que possui o menor erro quadrático médio, possui topologia 3:6:1 (3 neurônios na primeira camada escondida, 6 na segunda e 1 na camada de saída) conforme a representação da Figura 14:



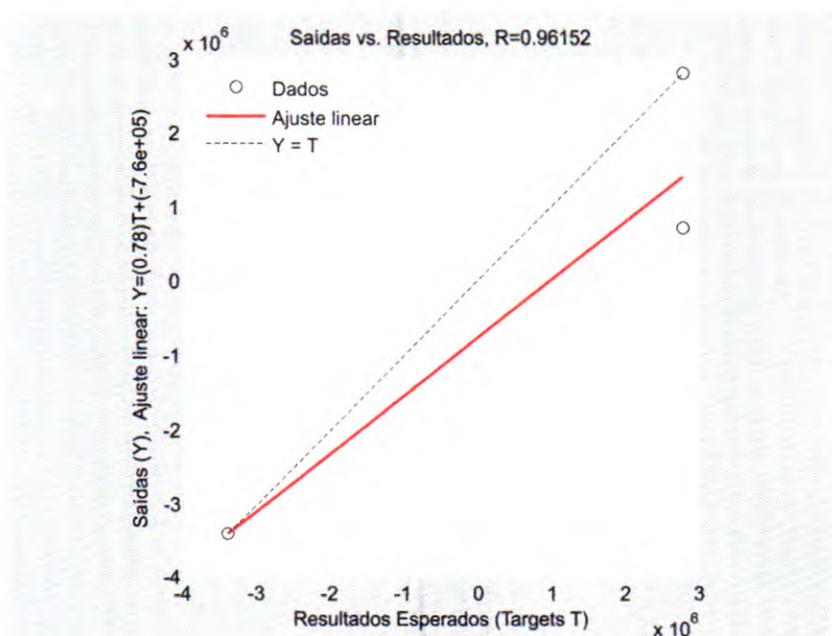
**Figura 14.** Representação da melhor configuração da RNA encontrada pelo processo de validação cruzada.  
Fonte: (O autor, 2015).

Foram utilizadas 30 amostras para serem submetidas à rede neural, do total 60% foram selecionadas aleatoriamente para compor o conjunto de treinamento. Para esse conjunto, como resultado a rede apresentou 90,92% de aprendizado com as amostras, conforme apresentado na Figura 15:



**Figura 15.** Gráfico resultante do conjunto de treinamento, realizado na rede neural MLP.  
**Fonte:** (O autor, 2015).

Para o conjunto de treinamento, acreditou-se que o alcance dos resultados ocorreu pela quantidade de entradas inseridas na rede. A capacidade de generalização do aprendizado e a capacidade classificação de padrões possibilitou um acerto de quase 100% na fase de testes da Rede MLP, conforme a Figura 16.

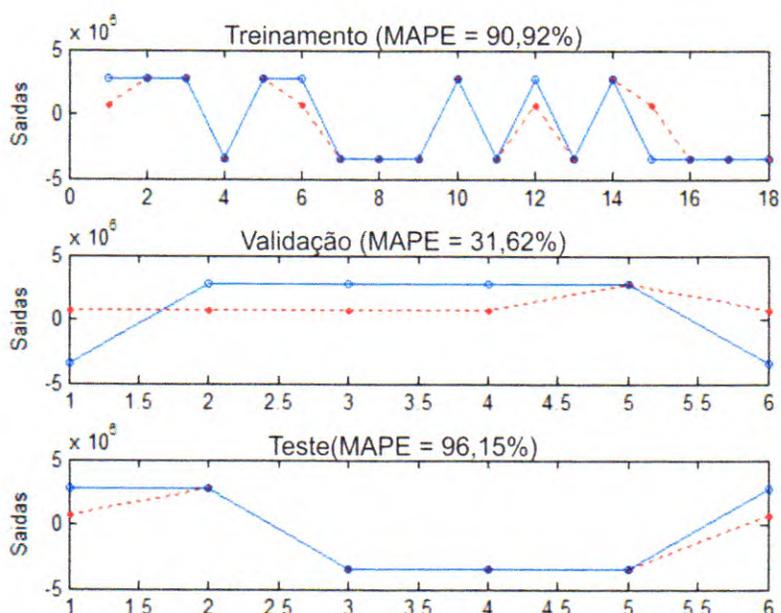


**Figura 16.** Gráfico de comparação entre os novos dados inseridos com as saídas desejadas, sob o conjunto de teste.

**Fonte:** (O autor, 2015).

Observou-se que o resultado do treinamento representado por  $R = 0.96152$  na Figura 16, foi alcançado com aplicação da função de ativação degrau bipolar em conjunto com a técnica de validação cruzada, que correlacionou o conjunto de teste para avaliar e validar a melhor generalização, adequando os pesos, todas as vezes que os resultados não correspondiam com o desejado.

O conjunto de testes realizados para validação, descreve junto com o treinamento, os erros com os quais garante a generalização do aprendizado, o que permite identificar qual a melhor RNA e em quantas épocas foram executadas. O resultado de cada etapa do modelo desenvolvido mostrou-se capaz de desempenhar a função de classificação (Figura 17).



**Figura 17.** Relação dos resultados obtidos nas fases de treinamento, validação e teste. Saídas desejadas (○) Saídas da RNA (●).

**Fonte:** (O autor, 2015).

A partir dos resultados, conclui-se como eficiente a relação dos dados de entrada e a rede MLP para validar o conjunto usado para teste, na classificação das duas espécies de folhas da família *Plectranthus*.

## CONSIDERAÇÕES FINAIS

Este trabalho apresentou o uso de técnicas de processamento digital de imagens para extração de características de dois tipos de folhas da família *Plectranthus*, coletadas no horto de plantas medicinais Farmácia Viva. Finalizado o processamento, foi encontrado o conjunto de dados valorados do limbo e pecíolo, que foi de grande importância para caracterizar cada amostra e compor as entradas do método de classificação das imagens.

Desenvolveu-se neste trabalho o algoritmo de Rede Neural *Perceptron* Multicamadas, que se apossou do conjunto de dados fornecidos pela fase de pré-processamento das imagens. O algoritmo mostrou qualidade em associar um padrão de entrada (amostra) para uma das duas classes previamente definidas, para classificação das folhas da família *Plectranthus*. O reconhecimento proposto foi apresentado em um resultado de classificação satisfatório, pois a taxa de classificação obtida por ele está entre as melhores na literatura.

Tendo em vista o aspecto da contribuição, a utilização de técnicas de processamento digital de imagens e inteligência computacional descritos auxilia no estabelecimento de métricas e métodos para o reconhecimento de imagens de folhas, apontando características morfológicas presentes no limbo, bem como métricas e conjunto de cores encontradas no pecíolo. No campo de redes neurais artificiais foi mostrada a eficiência da rede MLP, com o algoritmo *backpropagation* para classificação de padrões e sua eficácia nessa aplicabilidade.

É possível encontrar outras características da folha, aplicando outras técnicas processamento digital de imagem, como por exemplo, utilização de fractais para extração da nervura e apontar se existe um padrão na formação das nervuras; podem-se utilizar métodos que identifiquem como é a forma da borda (inteiro, dentado, serrilhado e outros); apontar métricas quanto ao ângulo que formam o ápice e à base presentes na folha.

Este trabalho abrangeu apenas a rede neural do tipo MLP, deixando espaço para possíveis trabalhos que poderiam utilizar as mesmas métricas de entradas utilizadas e aplicá-las a outras redes *feedforward* de camadas múltiplas, como por exemplo, uma rede RBF (*Radial Bases Function*). Outra possibilidade, seria obter mais parâmetros que caracterize a família *Plectranthus*, em acréscimo dos dados obtidos, para classificar espécies de famílias diferentes por meio da folha.

## REFERÊNCIAS

- ACHARYA, T.; RAY, A. K. **Image Processing**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2005.
- ARNOUS, A. H. et al. **PLANTAS MEDICINAIS DE USO CASEIRO - CONHECIMENTO POPULAR E INTERESSE POR CULTIVO COMUNITÁRIO MEDICINAL**. Londrina Revista Espaço para a Saúde, , 2005.
- ATA, R. **Artificial neural networks applications in wind energy systems: a review**. Renewable and Sustainable Energy Reviews, v. 49, p. 534–562, set. 2015.
- AZEVEDO, E.; CONCI, A. **Teoria da computação gráfica**. Rio de Janeiro: Editora Campus, 2003.
- BASHEER, I. A.; HAJMEER, M. **Artificial neural networks: fundamentals, computing, design ,and application**. Journal of Microbiological Methods, v. 43, p. 3–31, 2000.
- BORGES, T. H. **Sistema de classificação de plantas por meio de suas folhas usando uma arquitetura híbrida composta por algoritmos genéticos e rede neural artificial**. Universidade Federal de Uberlândia, 2013.
- BOVIK, A. C. **The Essential Guide to Image Processing**. California: Elsevier Inc., 2009.
- ENGELBRECHT, A. P. **Computational Intelligence an Introduction**. 2nd. ed. Canada: John Wiley & Sons Canada Ltd, 2007.
- EUSTÁQUIO, J.; QUEIROZ, R. DE; GOMES, H. M. **Introdução ao Processamento Digital de Imagens**. Rita, v. 8, n. 1, p. 1–31, 2001.
- FARIA, R. D. E. O. **Desenvolvimento de um sistema de monitoramento de dispersoides baseado em análise de imagens**. [s.l.] Lavras: Universidade Federal de Lavras, 2013.
- FERREIRA, T.; RASBAND, W. **ImageJ User Guide IJ 1.46r**. Disponível em: <<http://imagej.nih.gov/ij/docs/guide/146.html>>. Acesso em: 27 out. 2015.
- FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing Second Edition**. 2. ed. [s.l.] Prentice Hal, 2002.
- HANSEN, C. D., JOHNSON, C. R. **Visualization Handbook**. [s.l.] Elsevier, 2005.
- JOLY, M. **Introdução à análise da imagem**. Lisboa: Edições 70 Lda, 2007.
- KADIR, A. et al. **Leaf Classification Using Shape, Color, and Texture Features**. International Journal of Computer Trends and Technology, p. 225–230, 2011.

- KURISCAK, E. et al. **Biological context of Hebb learning in artificial neural networks, a review.** *Neurocomputing*, v. 152, p. 27–35, 2015.
- MATOS, F. J. DE A. **Plantas medicinais: guia de seleção e emprego de plantas medicinais usadas em fitoterapia no Nordeste do Brasil.** Fortaleza: UFC, v. 2, 2000.
- RUSSELL C. EBERHART; SHI, Y. **Computational Intelligence Concepts to Implementations.** [s.l.] Elsevier Inc., 2007.
- SANTOS, E. J. D. DOS. **Aplicação de Redes Neurais Artificiais na Análise do Encapsulamento de Bobinas de Transformadores.** [s.l.] Universidade Estadual de Londrina, 2013.
- SCHIAVONI, S. **Um estudo comparativo de métodos para balanceamento do conjunto de treinamento em aprendizado de redes neurais artificiais.** Universidade Federal de Lavras, 2010.
- SHAPIRO, L. G.; STOCKMAN, G. C. **Computer vision.** Upper Saddle River, NJ: Prentice Hall, 2001.
- SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático.** São Paulo, SP: Artliber Editora Ltda, 2010.
- SILVA, R. R. DA. **Reconhecimento de Imagens Digitais Utilizando Redes Neurais Artificiais.** Universidade Federal de Lavras, 2005.
- SILVA, P. F. B. **Development of a System for Automatic Plant Species Recognition.** [s.l.] Faculdade de Ciências da Universidade do Porto, 2013.
- SOUZA, M. S. et al. **PROSPECÇÃO TECNOLÓGICA: APLICAÇÕES FITOTERÁPICAS DO BOLDO.** ANAIS DO SIMPÓSIO INTERNACIONAL DE INOVAÇÃO TECNOLÓGICA - SIMTEC, v. 1, n. 1, p. 592–603, 27 set. 2013.
- TARALLO, A. DE S. **Segmentação e Classificação de Imagens Digitais de Úlceras Cutâneas Através de Redes Neurais Artificiais.** [s.l.] Universidade de São Paulo, São Carlos, 2007.
- ULUTURK, C.; UGUR, A. **Recognition of leaves based on morphological features derived from two half-regions** INISTA 2012 - International Symposium on INnovations in Intelligent SysTems and Applications. *Anais...*2012
- VIDAL, W. N.; VIDAL, M. R. R. **Botânica Organografia: Quadros Sinóticos Ilustrados de Fenorógamos.** 4.ed. rev. ed. Viçosa: Universidade Federal de Viçosa, 2006.
- WU, S. G. et al. **A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network.** *Signal Processing and Information Technology*, 2007 IEEE International Symposium, 2007. Disponível em:

<[http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=4458016](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=4458016)>

YILMAZ, I.; KAYNAR, O. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. **Expert Systems with Applications**, v. 38, n. 5, p. 5958–5966, 2011.