

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS AGRÁRIAS E DE TECNOLOGIA
DEPARTAMENTO DE INFORMÁTICA
MESTRADO EM COMPUTAÇÃO APLICADA

GEISLA DE ALBUQUERQUE MELO

UTILIZAÇÃO DE PROCESSAMENTO DIGITAL DE IMAGENS E REDES
NEURAIS ARTIFICIAIS PARA O RECONHECIMENTO DE ÍNDICES DE
SEVERIDADE DA FERRUGEM ASIÁTICA DA SOJA

PONTA GROSSA

2015

GEISLA DE ALBUQUERQUE MELO

UTILIZAÇÃO DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS E
REDES NEURAIS ARTIFICIAIS PARA O RECONHECIMENTO AUTOMÁTICO
DA SEVERIDADE DA FERRUGEM ASIÁTICA DA SOJA

Dissertação apresentada para a obtenção do título de
mestre na Universidade Estadual de Ponta Grossa,
Pró-Reitoria de Pesquisa e Pós-Graduação, Mestrado
em Computação Aplicada, Área de Concentração
Tecnologias para a Agricultura.

Orientador: Prof. Dr. Ivo Mario Mathias

PONTA GROSSA

2015

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

M528 Melo, Geisla de Albuquerque
Utilização de técnicas de processamento digital de imagens e redes neurais artificiais para o reconhecimento automático da severidade da ferrugem asiática da soja/ Geisla de Albuquerque Melo. Ponta Grossa, 2015.
109f.

Dissertação (Mestrado em Computação Aplicada - Área de Concentração: Agricultura), Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Ivo Mario Mathias.

1.BRNeural. 2.Back-propagation. 3.Resilient-propagation. 4.Inteligência Artificial. 5.Visão Artificial. I.Mathias, Ivo Mario. II. Universidade Estadual de Ponta Grossa. Mestrado em Computação Aplicada. III. T.

CDD: 006.3

GEISLA DE ALBUQUERQUE MELO

UTILIZAÇÃO DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS E
REDES NEURAIS ARTIFICIAIS PARA O RECONHECIMENTO AUTOMÁTICO
DA SEVERIDADE DA FERRUGEM ASIÁTICA DA SOJA

Dissertação apresentada para obtenção do título de Mestre em Computação Aplicada,
na Universidade Estadual de Ponta Grossa.

Ponta Grossa, _____ de _____ de _____.

Ivo Mario Mathias

Prof. Doutor em Agronomia

Universidade Estadual de Ponta Grossa

Alceu de Souza Britto Jr.

Prof. Doutor em Informática Aplicada

Universidade Pontifícia Católica do Paraná/ Universidade Estadual de Ponta Grossa

David de Souza Jaccoud Filho

Prof. Doutor em Fitopatologia

Universidade Estadual de Ponta Grossa

AGRADECIMENTOS

Agradeço em primeiro lugar ao Deus pai todo poderoso, pois sem Ele, se quer eu estaria aqui. Por muitos motivos pensei em desistir no meio do caminho, por uma série de problemas que vieram ao mesmo tempo, mas Deus sempre me sustentou, nunca me deixou cair.

Agradeço ao meu mui estimado orientador Ivo Mario Mathias, simplesmente por tudo. Agradeço não só pelas orientações, mas pelas palavras amigas, pelos incentivos, pelas conversas, pelos desabafos, pela amizade. Sempre que conversávamos, eu saía de sua sala mais animada e mais determinada a seguir em frente. O levarei para sempre em meu coração.

Agradeço a minha mãe Eliane que tanto amo, por seu apoio, seu amor incondicional. Agradeço pela ajuda financeira, sem a qual não conseguiria dar continuidade aos estudos.

Agradeço ao meu noivo Ricardo Ferreira Laskoski, por todo seu amor, por toda sua paciência. Quando eu mais estava estressada, nervosa com os prazos, com raiva porque os testes não funcionavam, enfim, quando eu menos mereci, foi quando eu mais precisei, e foi quando mais ele esteve presente. Agradeço por todas as dicas e toda a ajuda técnica, sem a qual eu também não teria conseguido.

Agradeço ao professor David de Souza Jaccoud Filho, do grupo de Fitopatologia Aplicada, do curso de Agronomia da UEPG, por toda a prestatividade, todo o apoio, incentivo, e toda a parceria que firmamos durante a pesquisa. Seu apoio foi ímpar e fundamental para a continuidade do trabalho.

Agradeço aos alunos do professor David, também do grupo de Fitopatologia Aplicada, César Baran, Hamilton Edemundo Tullio, Guilherme de Camargo Huller, Felipe Manfron, Letícia Marise Lamana e Ana Paula Teixeira. Agradeço por realizarem as coletas das folhas tantas vezes comigo. Em especial ao Hamilton, Guilherme e ao Felipe por ficarem horas e horas analisando a severidade daquelas mais de 3 mil folhas de soja. Meu muito obrigada mesmo, são pessoas incríveis.

Agradeço ao amigo Roberson Júnior Fernandes Alves, por sua ajuda fundamental durante todo o estudo de caso, pondo em prática todos os testes mais loucos que vinham na minha cabeça. Agradeço pela paciência comigo nesta etapa, pois seu apoio proporcionou a parte inicial do aplicativo, essencial para minha dissertação.

Agradeço ao amigo Luiz Antônio Zanlorenzi Júnior, por toda sua atenção comigo quanto ao BrNeural, por ter feito as modificações necessárias no simulador que eu precisava para se encaixar ao meu trabalho. Agradeço pois sempre disse “sim”.

Agradeço à professora Elaine Margarete Guimarães, que dedicou algumas tardes me orientando, sanando muitas dúvidas lá do início do trabalho.

Agradeço também ao professor José Carlos, que também doou seu tempo para me orientar e dar dicas quanto aos rumos que o trabalho estava tomando em seus primeiros passos.

Meu muito obrigada aos meus mestres, por sempre, sempre estarem dispostos a me ajudar.

Agradeço também à CAPES, pela bolsa, auxílio financeiro que possibilitou a pesquisa.

Por fim, agradeço a todos que direta ou indiretamente contribuíram para a conclusão deste trabalho.

“Conhecimento não é aquilo que você sabe, mas o que você faz com aquilo que você sabe.”

Aldous Huxley

“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes.”

Marthin Luther King

“Quanto mais aumenta nosso conhecimento, mais evidente fica nossa ignorância.”

John F. Kennedy

RESUMO

Segundo a Embrapa (2013), o Brasil é o segundo maior produtor de soja do mundo, atrás apenas nos Estados Unidos. Safra após safra, a produção e a área plantada do Brasil vem crescendo, entretanto, fatores climáticos e doenças da cultura vêm afetando as lavouras, impedindo um crescimento ainda maior, e causando perdas para os agricultores. A ferrugem asiática, causada pelo fungo *Phakopsora pachyrhizi*, é uma doença foliar, considerada uma das doenças de maior importância na atualidade, devido ao grande potencial de perdas. A ferrugem asiática pode ser confundida com outras doenças na soja, como o Crestamento Bacteriano, a Mancha Parda e a Pústula Bacteriana, devido às aparências visuais semelhantes. Deste modo, O presente estudo teve por objetivo desenvolver um aplicativo para dispositivos móveis que utilizam a plataforma *Android*, para realizar o reconhecimento automático dos índices de severidade da ferrugem asiática da soja, para auxiliar no diagnóstico precoce e por consequência, auxiliar na tomada de decisão quanto ao manejo e controle da doença. Para isto, foram utilizadas técnicas de Processamento Digital de Imagens (PDI) e Redes Neurais Artificiais (RNA). Primeiramente, foram coletadas aproximadamente 3 mil folhas de soja em campo, onde cerca de 2 mil foram aproveitadas. Então elas foram separadas por índices de severidade, fotografadas em ambiente controlado, e após isto foram processadas com o objetivo de eliminar ruídos e o fundo das imagens. A fase de filtragem do pré-processamento consistiu nos filtros da mediana, filtro Gaussiano, transformação para escala de cinza, detector de bordas *Canny*, dilatação, *find* e *drawcontours*, e por fim o recorte da folha. Após isto, foram extraídas as características de cor e textura das imagens, que foram as médias R, G e B, Variância também para os três canais R, G e B, Segundo Momento Angular, Entropia, Contraste, Homogeneidade, Correlação e por fim, o Grau de Severidade previamente sabido. Com estes dados, foi realizado o treinamento de uma RNA através do simulador de redes neurais BrNeural. Durante o treinamento, parâmetros como quantidade de níveis de severidade e quantidade de neurônios da camada oculta foram alterados. Após o treinamento, foi escolhida a arquitetura de rede que deu melhor resultado, com 78,86% de acerto para o algoritmo *Resilient-propagation*. Esta rede foi salva em um objeto e inserida no aplicativo, pronta para ser utilizada com dados novos. Assim, o aplicativo tira a foto da folha de soja e faz a filtragem da imagem adquirida. Após isto, extrai as características e manda internamente para a rede neural treinada, que analisa e informa a severidade. Ainda, opcionalmente é possível ver um mapa georreferenciado da propriedade, com as severidades identificadas por pequenos quadrados coloridos, representando cada um, um índice diferente.

Palavras-chave: BRNeural; Back-propagation; Resilient-propagation; Inteligência Artificial; Visão Artificial; OpenCv.

ABSTRACT

According to Embrapa (2013), Brazil is the world's second largest soy producer just after the United States. Season after season, the production and planted area in Brazil is growing, however, climatic factors and crop diseases are affecting plantation, preventing further growth, and causing losses to farmers. Asian rust caused by *Phakopsora pachyrhizi*, is a foliar disease, considered one of the most important diseases at present, because of the potential for loss. Asian rust can be mistaken for other diseases in soybeans, such as Bacterial Blight, a Stain Brown and Bacterial Pustule, due to similar visual appearances. Thus, the present study aimed to develop an application for mobile devices using the Android platform to perform automatic recognition of the Asian soybean rust severity indices to assist in the early diagnosis and therefore assist in decision-making as the management and control of the disease. For this, was used techniques of digital image processing (DIP) and Artificial Neural Networks (ANN). First, around 3.000 soybean leaves were collected in the field, where about 2.000 were harnessed. Then it were separated by severity index, photographed in a controlled environment, and after that were processed in order to eliminate noise and background images. Filtering preprocessing phase consisted of median filter, Gaussian filter processing for gray scale, Canny edge detector, expansion, find and drawcontours, and finally the cut of leaf. After this was extracted color and texture features of the images, which were the average R, G and B Variant also for the three channels R, G and B according angular momentum, entropy, contrast, homogeneity, and finally correlation the severity degree previously known. With these data, the training was performed an ANN through the neural network simulator BrNeural. During training, parameters such as number of severity levels and number of neurons of the hidden layer have changed. After training, was chosen network architecture that gave better results, with 78.86% accuracy for Resilient-propagation algorithm. This network was saved in an object and inserted into the application, ready to be used with new data. Thus, the application takes the soybean leaf picture and filters the acquired image. After this, it extracts the features and commands internally to the trained neural network, which analyzes and reports the severity. Still, it is optionally possible to see a georeferenced map of the property, with the severities identified by small colored squares, each representing a different index.

Keywords: BRNeural; Back-propagation; Resilient-propagation; Artificial Intelligence; Artificial Vision; OpenCv.

LISTA DE FIGURAS

Figura 1 - Produção de soja no Brasil. Evolução por estado	18
Figura 2 - Área das principais culturas no Brasil	19
Figura 3 - Sintomas iniciais de ferrugem asiática na face abaxial da folha de soja	23
Figura 4 - Pústulas de <i>Phakopsora pachyrhizi</i> na face inferior da folha de soja	23
Figura 5 - Uredias com poros abertos de <i>Phakopsora pachyrhizi</i>	24
Figura 6 - Danos decorrentes da infecção de <i>Phakopsora pachyrhizi</i>	25
Figura 7 - Ciclo da Ferrugem Asiática	27
Figura 8 - Escala diagramática para severidade da ferrugem da soja (percentual da área doente da folha).....	28
Figura 9 - Um Sistema de Visão Artificial (SVA) e suas principais etapas.....	32
Figura 10 - Cubo representando o espaço de cores RGB	36
Figura 11 - Baboon e seu espectro de Fourier	41
Figura 12 - Hierarquia de Aprendizado	46
Figura 13 - Neurônio biológico simplificado	49
Figura 14 - Neurônio artificial.....	50
Figura 15 - Exemplo de RNA multicamadas típica.....	50
Figura 16 - Coleta das folhas de soja realizada na estufa no dia 10/07/2013.....	66
Figura 17 - Escala diagramática para severidade do oídio da soja.....	67
Figura 18 - Estrutura da RNA utilizada.....	70
Figura 19 - Segunda coleta de folhas.....	72
Figura 20 - Terceira coleta de folhas	72
Figura 21 - Folhas de soja incubadas em saco plástico	73
Figura 22 - Cúpula em madeira	74
Figura 23 - Cúpula em acrílico	75
Figura 24 - Folha de soja sadia.....	76
Figura 25 - Folha com 3% de severidade	76
Figura 26 - Folha de soja com 10,1 a 15% de severidade	77
Figura 27 - Folha de soja com 20,1 a 30% de severidade	77
Figura 28 - Folha de soja com 30,1 a 40% de severidade	78
Figura 29 - Folha de soja com 40,1 a 50% de severidade	78
Figura 30 - Trecho arquivo de características .csv	82
Figura 31 - <i>Encog Workbench</i>	83
Figura 32 - Tela Principal BrNeural	84
Figura 33 - Tela de Relatório.....	84
Figura 34 - Tela inicial do aplicativo.....	92
Figura 35 - Aviso de GPS desabilitado	93
Figura 36 - Habilitar GPS do aparelho	94
Figura 37 - Mapa gerado pelo aplicativo.....	95

LISTA DE TABELAS

Tabela 1 - Matriz de Coocorrência	37
Tabela 2 - Distribuição dos Níveis de Severidade.....	75
Tabela 3 - Melhores Resultados Primeiro Cenário.....	87
Tabela 4 - Melhores Resultados Segundo Cenário.....	88
Tabela 5 - Melhores Resultados Terceiro Cenário	88
Tabela 6 - Melhores Resultados Quarto Cenário.....	89
Tabela 7 - Melhores Resultados Quinto Cenário.....	89
Tabela 8 - Melhores Resultados Sexto Cenário.....	90
Tabela 9 - Melhores Resultados Sétimo Cenário	90
Tabela 10 - Matriz de Confusão da estrutura de rede escolhida.....	91

LISTA DE QUADROS

Quadro 1 - Descritores de Textura baseados nas matrizes de coocorrência.....	39
Quadro 2 - Etapas dos Filtros de Processamento de Imagem.....	69
Quadro 3 - Etapas do pré-processamento das folhas.....	80

SUMÁRIO

1. INTRODUÇÃO.....	12
1.1 Proposta	15
1.2 Justificativa	15
1.3 Organização do Trabalho.....	16
2. FUNDAMENTAÇÃO TEÓRICA	17
2.1 A Ferrugem Asiática e a Agricultura	17
2.1.1 A soja na Agricultura do Brasil.....	17
2.1.2 Doenças da Soja	19
2.1.3 A Ferrugem Asiática da Soja	21
2.2 Sistemas de Visão Computacional.....	29
2.2.1 O processamento Digital de Imagens (PDI).....	29
2.2.2 O sistema Visual Humano e o PDI	30
2.2.3 Etapas do Processamento Digital de Imagens.....	31
2.3 Inteligência Artificial e Aprendizado de Máquina.....	43
2.3.1 Redes Neurais Artificiais	47
2.4 Aplicações Móveis.....	56
2.4.1 Benefícios dos Aplicativos Móveis na Agricultura.....	57
2.4.2 A Plataforma <i>Android</i>	57
2.5 Trabalhos Correlatos	58
3. MATERIAIS E MÉTODOS.....	65
3.1 Estudo de Caso.....	65
3.2 Aquisição das Imagens	71
3.3 O Processamento Digital das Imagens.....	79
3.4 Configuração e Treinamento da Rede Neural.....	82
3.5 O Aplicativo e suas características	86
4. RESULTADOS	87
5. CONSIDERAÇÕES FINAIS	96
6. CONCLUSÕES	98
Referências	99

1. INTRODUÇÃO

O Brasil exerce um importante papel na produção agrícola mundial, ocupando posições de destaque na produção de vários alimentos. Dados da Conab (Companhia Nacional de Abastecimento) apontam que a produção de grãos no Brasil na safra 2013/2014 atingiu 193,47 milhões de toneladas, 2,6% superior à obtida na safra 2012/2013, quando atingiu 188,66 milhões de toneladas, isto é, um ganho de 4,81 milhões de toneladas em relação à safra 2012/2013. O total de área plantada chegou a 56,85 milhões de hectares, o que significa uma alta de 6,1%, se comparado à de 53,56 milhões de hectares da safra 2012/2013, um aumento de 3,29 milhões de hectares (CONAB, 2014).

A soja é um dos principais grãos da produção agrícola no Brasil. Segundo a Embrapa Soja (2013), o país é o segundo maior produtor mundial dos grãos, onde obteve uma produção de 81,5 milhões de toneladas na safra 2012/2013, atrás apenas dos Estados Unidos, com uma produção de 82,6 milhões de toneladas no mesmo período. O Paraná é o segundo estado brasileiro que mais produz a soja, com 15,9 milhões de toneladas de produção, atrás do Mato Grosso, com 23,5 milhões de toneladas, na mesma safra. Segundo dados da Conab, na safra 2013/2014 a produção alcançou 85.65 milhões de toneladas e área plantada de 30.135 mil hectares, um aumento de 5,1% da produção e de 8,7% na área plantada (CONAB, 2014).

Apesar de apresentar altos níveis de produção, uma das limitações da produção da soja são as doenças, responsáveis por perdas anuais de 15 a 20%, entretanto, há casos em que algumas doenças causam perdas de 100% na produção (EMBRAPA SOJA, 2013).

A ferrugem asiática, causada pelo fungo *Phakopsora pachyrhizi*, é uma doença foliar que apresenta lesões de cor marrom claro e escuro, especialmente na parte inferior das folhas da soja. É uma das doenças de maior importância na atualidade, devido ao grande potencial de perdas (EMBRAPA SOJA, 2013).

A ferrugem asiática pode ter seu diagnóstico dificultado, pois pode ser confundida com outras, como o Crestamento Bacteriano, a Mancha Parda e a Pústula Bacteriana, devido às aparências das lesões serem muito semelhantes. Por vezes, a certeza da doença é dada pela constatação de pequenas esporulações na parte posterior da folha, vista com o auxílio de uma lupa de 10 a 20 aumentos (EMBRAPA SOJA, 2013).

Segundo a Fundação de Apoio à Pesquisa do Corredor de Exportação Norte (FAPCEN, 2014), a Associação de Produtores de Soja e Milho de Mato Grosso (Aprosoja) calcula que os prejuízos causados pela ocorrência de ferrugem asiática nas lavouras de soja em todo país, chega a US\$ 19,7 bilhões, entre as safras de 2001/2002 a 2010/2011.

Consideram nos cálculos os gastos com controle químico, perda de produtividade e de arrecadação de impostos. Este prejuízo torna-se expressivo, levando em conta que dados da CNA (Confederação da Agricultura e Pecuária do Brasil) mostram que o setor agrícola brasileiro deve faturar R\$ 298,4 bilhões em 2014, 8,2% superior a 2013. Deste faturamento, a receita anual da soja deve crescer para R\$ 96,2 bilhões, ou 10% mais ante 2013 (FAEMG, 2014).

As perdas variam, entre outros fatores, em função da suscetibilidade da cultivar, épocas de semeadura, condições climáticas, da rapidez no diagnóstico e tratamento da doença. Neste cenário, entre as práticas de manejo e controle da ferrugem asiática, existem as aplicações preventivas, a rotação de culturas e ainda o monitoramento da doença, que alerta quanto ao risco da doença em determinadas regiões, favorecendo a diminuição de perdas (EMBRAPA SOJA, 2013).

A tecnologia vem evoluindo com o passar do tempo, atuando nas mais diversas áreas do conhecimento. Hoje, é possível abrir e dar partida em um automóvel sem chave, também já é possível detectar doenças em fetos apenas pelo sangue da mãe, muito comum também ver pessoas pagando contas via celular, e cirurgias sendo realizadas por robôs inteligentes. Assim, sistemas computadorizados passaram a atuar mais frequentemente em todas estas áreas. Na agricultura, a presença desta tecnologia é notável. Observa-se a utilização de tratores automatizados, sistemas para previsibilidade de insumos bem como para apoio meteorológico, sistemas para agricultura de precisão, entre outros.

Sistemas que fazem processamento de imagens e reconhecimento de padrões vêm sendo utilizados em áreas como ciência dos materiais (ALBUQUERQUE *et al*, 2007), urbanismo (BOTELHO & CENTENO, 2005) e medicina (VERONEZI *et al*, 2011), pois substituem a forma convencional em que humanos realizam esta tarefa, que por vezes é imprecisa.

Com o uso de Processamento Digital de Imagens (PDI) é possível tratar as imagens adquiridas, de modo a aprimorá-las para a interpretação humana e também prepará-las para a análise automática por computador, ou seja, classificação do reconhecimento de padrões (MARQUES FILHO & VIEIRA NETO, 1999).

Na agricultura, o processamento digital está presente no mapeamento de áreas plantadas (JOHANN *et al*, 2012), no reconhecimento de patologias em culturas (PIRES *et al*, 2009), análises de uso do solo (OLIVEIRA BATISTA & LEAL SANTOS, 2011) e detecção de queimadas (GONÇALVES *et al*, 2012), entre outras.

Dentro deste contexto, nota-se a *OpenCv* (*Open Source Computer Vision Library*), que é uma biblioteca projetada para o desenvolvimento de aplicações de visão computacional, que fornece a infraestrutura adequada para o tratamento e análise de imagens. Deste modo, o uso da biblioteca *OpenCv* visa auxiliar na realização de funções de processamento de imagens, contribuindo com aplicações que envolvam e necessitem de manipulação e análise de imagens. A biblioteca possui versões para as linguagens de programação de computador Java (JAVA, 2015), C (OPEN STD, 2015), C++ (OPEN STD, 2015) e Python (PYTHON, 2015). Há também um SDK (*Software Development Kit* – ou como tradução livre, Kit de Desenvolvimento), para a Plataforma *Android*, que é um sistema operacional para celulares e *smartphones* (OPENCV, 2013).

Segundo a Organização das Nações Unidas, há seis bilhões de celulares em âmbito mundial (ONU, 2013), e até o fim de 2014, a previsão era de que o mundo teria 7 bilhões de assinaturas de celulares, uma para cada habitante do planeta. Outro dado apontado é que o mundo já possui quase 3 bilhões de usuários da internet (ONU, 2014). Segundo o site de estatísticas de mercado para tecnologias *Net Applications*, a plataforma *Android*, em julho de 2014, alcançou a liderança no ranking dos sistemas operacionais móveis mais usados no mundo, com 44,62% do mercado (NET APPLICATIONS, 2014).

A plataforma *Android* é um software de código aberto desenvolvido pela empresa *Google* (ANDROID, 2014), para uma ampla variedade de dispositivos móveis. Sendo de código aberto, é possível que usuários comuns com conhecimento em desenvolvimento de programas, tenham a possibilidade de desenvolver aplicações para esta plataforma, de modo que estas possam ser executadas em qualquer dispositivo que possua este SO.

Uma rede neural é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001). Estas redes se caracterizam por um funcionamento similar ao da troca de informações dos neurônios do cérebro humano, e assim são capazes de “aprender”, se treinadas adequadamente. Encontra-se aplicada na análise de dados agrícolas (MATHIAS, 2006), na classificação automática de cultivares (RAMOS, 2003), e no auxílio à tomada de decisão (BRESSAN, 2004).

O desenvolvimento desta pesquisa deu-se em parceria com o grupo de Fitopatologia Aplicada do curso de Agronomia da Universidade Estadual de Ponta Grossa. Com os estudos e reuniões promovidas em conjunto com o mesmo, foi possível amadurecer a ideia, podendo efetivamente ao final contribuir para a área, mantendo a pesquisa coerente com a realidade

face ao auxílio no diagnóstico da ferrugem asiática da soja. Este apoio foi fator determinante de estímulo à continuidade das pesquisas para a realização do trabalho.

1.1 Proposta

O objetivo geral do presente estudo é desenvolver um aplicativo para dispositivos móveis, capaz de realizar o reconhecimento automático de índices de severidade da doença Ferrugem Asiática da cultura da soja (respeitando uma escala de severidade) mediante a apresentação de uma folha de soja ao mesmo. Para isto, são empregadas técnicas de Processamento Digital de Imagens e Inteligência Artificial, através das Redes Neurais Artificiais.

Como objetivos específicos, teve-se em primeiro lugar, encontrar a melhor combinação de tarefas de processamento de imagens que possibilitem chegar a uma imagem final apropriada para a análise posterior, bem como encontrar os melhores descritores da imagem em questão, para que o reconhecimento de padrões obtivesse um resultado suficiente.

Em segundo lugar, objetivou-se que o aplicativo realizasse todo o reconhecimento via dispositivo móvel, não havendo tarefas que requeiram resposta de processamento externa ao dispositivo, tampouco que necessitem de conexão com a rede.

Assim, propôs-se ser possível ao fotografar a folha, retornar o resultado da análise de severidade em tempo real, visando maior confiabilidade e rapidez em relação ao mesmo procedimento realizado de maneira manual convencional. Ao final do processo, opcionalmente será possível visualizar um mapa da área com destaques para os níveis e localizações das severidades registradas.

1.2 Justificativa

A pesquisa torna-se justificável ao observar o fato de que na realização da análise da doença de modo convencional, o diagnóstico pode ser impreciso, devido à semelhança com outras doenças. Vale lembrar que a ferrugem asiática da soja pode ser confundida com as doenças mancha parda (*Septoria glycines*), cretamento bacteriano (*Pseudomonas savastanoi* pv. *glycinea*), pústula bacteriana (*Xanthomonas axonopodis* pv. *glycines*) e ainda até mesmo danos por herbicidas pós-emergentes (EMBRAPA SOJA, 2013). Em todos os casos de acometimento, as folhas afetadas amarelam, secam e caem precocemente, dificultando e confundindo a distinção. No caso da ferrugem, a presença das uredias (pústulas) permite

diferenciá-la das demais doenças. Este fator torna fundamental o uso da lupa de 10 x a 20x de aumento para assegurar a identificação, quando não há experiência suficiente (EMBRAPA SOJA, 2013).

A pesquisa visa buscar meios para facilitar o correto diagnóstico, uma vez que este será realizado de forma automática, com o auxílio de técnicas de inteligência artificial e processamento de imagens.

1.3 Organização do Trabalho

A organização do presente trabalho é descrita a seguir.

No Capítulo 2, tem-se a documentação bibliográfica do trabalho, cujo objetivo é fundamentar teoricamente o exposto. Aborda os assuntos Ferrugem Asiática e a Agricultura, Sistemas de Visão Computacional, Aprendizado de Máquina e Aplicações Móveis.

No Capítulo 3, são tratados dos Materiais e Métodos da pesquisa, a fim de explanar o desenvolvimento do trabalho. Aborda a preparação do estudo, descreve o estudo de caso realizado, fala sobre a aquisição e o processamento das imagens, a rede neural utilizada, as características, fotos e aspectos do aplicativo móvel.

O Capítulo 4 traz os resultados da pesquisa, incluindo acuracidade da rede neural, testes e o funcionamento do aplicativo.

Já no Capítulo 5, são apresentadas as considerações finais do estudo.

Por fim, tem-se o Capítulo 6, que abrange as conclusões do estudo, bem como traça um caminho de continuidade com perspectivas de trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

A seguir, são explanados alguns tópicos de fundamentação teórica, no intuito de prover melhor entendimento do estudo em questão.

2.1 A Ferrugem Asiática e a Agricultura

2.1.1 A soja na Agricultura do Brasil

A soja (*Glycine max* (L.) Merrill) é considerada uma das mais importantes fontes de proteína e óleo vegetal em todo o mundo. Tem sua origem em espécies de plantas rasteiras que se desenvolviam na costa leste da Ásia, em especial ao longo do Rio Amarelo, na China. Cientistas melhoraram para o consumo as espécies oriundas de cruzamentos naturais. No país, a soja juntamente com o trigo, o arroz, o centeio e o milheto, era considerada um grão sagrado devido à sua importância na dieta alimentar da antiga civilização chinesa, onde faziam rituais para semeadura e colheita (EMBRAPA SOJA, 2014).

Apesar de ser explorada no Oriente há mais de cinco mil anos (é reconhecida como uma das mais antigas plantas cultivadas do Planeta), o Ocidente só iniciou sua exploração no século XX, através dos Estados Unidos da América. No Brasil, a soja chegou via Estados Unidos, em 1882. O então professor da Escola de Agronomia da Bahia, Gustavo Dutra, efetuou os primeiros estudos para avaliar os cultivares do país (EMBRAPA SOJA, 2014).


Em 1900 e 1901, o Instituto Agrônomo de Campinas, SP, promoveu a primeira distribuição de sementes de soja para produtores paulistas. No Rio Grande do Sul a cultura encontrou condições climáticas favoráveis para sua produção, fazendo o Brasil na década de 40, figurar, como produtor do grão nas estatísticas internacionais, com uma produção de 25 mil toneladas. Só então a partir da década de 1960, devido à política de subsídios ao trigo que visava autossuficiência, que então a soja se tornou economicamente importante para o país. Nesse período, sua produção multiplicou-se por cinco (passando de 206 mil toneladas, em 1960, para 1,056 milhão de toneladas, em 1969) e 98% desse volume era produzido nos três estados da Região Sul, onde prevaleceu a escala trigo no inverno e soja no verão (EMBRAPA SOJA, 2014).

Na década de 70, a soja se consolidou como a principal cultura do agronegócio brasileiro, passando de 1,5 milhões de toneladas (1970) para mais de 15 milhões de toneladas (1979). Entre os fatores que contribuíram para este crescimento significativo, tem-se o

aumento da área cultivada (1,3 para 8,8 milhões de hectares), o expressivo incremento da produtividade (1,14 para 1,73t/ha) graças às novas tecnologias disponibilizadas aos produtores pela pesquisa brasileira. Mais de 80% do volume produzido na época ainda se concentrava nos três estados da Região Sul do Brasil (EMBRAPA SOJA, 2014).

Analisando sua expansão, nota-se que em 1970, menos havia apenas uma pequena participação na produção nacional de soja pelo centro-oeste. Já em 1980, essa participação aumentou significativamente, e continuava a aumentar safra após safra. Essa transformação promoveu o Estado do Mato Grosso, de produtor marginal à líder nacional de produção e de produtividade de soja (EMBRAPA SOJA, 2013), como está ilustrado na Figura 1.


Figura 1 - Produção de soja no Brasil. Evolução por estado



Fonte: CONAB, 2013.

A soja foi a única cultura a ter um crescimento expressivo na sua área cultivada ao longo de quase quatro décadas, ilustrado na Figura 2.

Figura 2 - Área das principais culturas no Brasil



Fonte: CONAB, 2013.

2.1.2 Doenças da Soja

Segundo dados da Embrapa Soja, no Brasil, mais de 40 doenças da soja causadas por fungos, bactérias, nematoides e vírus já foram identificadas. A tendência para este número é aumentar, devido à expansão do cultivo da soja para novas áreas do Brasil, ocasionando a monocultura. Estas doenças são um dos principais fatores limitantes para a obtenção de uma maior produtividade, em consequência, maiores lucros no cultivo.

A cada ano, o impacto econômico causado por cada doença em específico, varia de região para região. Esta variação se deve em especial às diferenças climáticas ocorridas a cada safra. As doenças são responsáveis por perdas anuais estimadas em torno de 15 a 20%, contudo, dependendo das variações climáticas e do tipo da doença, as perdas podem chegar a até 100% da área cultivada (EMBRAPA SOJA, 2013).

O cultivo para a produção de sementes, realizado no outono/inverno sob irrigação, favorece a sobrevivência de muitos fungos, inclusive os causadores da antracnose, da ferrugem, do cancro da haste, da podridão branca da haste, da podridão vermelha da raiz e dos nematoides de galhas e de cisto. Os cultivos seguintes de mesma época, que também são

realizados sob irrigação, (feijão, ervilha, melancia e tomate), são afetados pela podridão branca da haste, pela podridão radicular e mela de *Rhizoctonia* (*R. solani*) e pelos nematoides de galhas e nematoides de cisto (feijão e ervilha), e isto aumenta o potencial de inóculo desses patógenos para a safra seguinte de soja (EMBRAPA SOJA, 2013; AGROLINK, 2014).

Entre as principais doenças da soja identificadas no Brasil, no que diz respeito avaliação de perdas e às suas ocorrências, que podem ser esporádicas ou restritas, até à incidência generalizada nacionalmente, destacam-se (EMBRAPA SOJA, 2014):

- Ferrugem americana (*Phakopsora meibomiae*);
- Ferrugem asiática (*Phakopsora pachyrhizi*);
- Doenças foliares de final de ciclo:
 - Mancha parda (*Septoria glycines*);
 - Crestamento foliar de cercospora (*Cercospora kikuchii*).
- Mancha "olho-de-rã" (*Cercospora sojina*);
- Oídio (*Microsphaera diffusa*);
- Antracnose (*Colletotrichum dematium* var. *truncata*);
- Mancha alvo e podridão da raiz (*Corynespora cassiicola*);
- Crestamento bacteriano da soja (*Pseudomonas savastanoi* pv. *glycinea*);
- Nematoides de galhas (*Meloidogyne* spp.);
- Nematóide de cisto da soja (*Heterodera glycines*).

Cada uma das doenças tem seus respectivos prejuízos contabilizados ao final do ciclo da soja. Alguns fatores podem potencializar substancialmente seus danos. Por exemplo, em determinada safra podem ocorrer condições climáticas favoráveis, ou ainda algumas doenças podem ser associadas a outras na cultura de forma simultânea, ou mesmo o manejo do solo e controle das doenças pode não ser realizado de maneira adequada, bem como o diagnóstico pode ser falho quanto a conhecimento tardio, ou ainda a doença detectada pode não ser de fato a que está, ou as que estão acometendo a soja. Neste sentido, faz-se necessário um sistema integrado de manejo da cultura, focando em especial no diagnóstico correto e precoce das doenças, visando a diminuição de perdas causadas pelas mesmas (EMBRAPA SOJA, 2014).

2.1.3 A Ferrugem Asiática da Soja

A cultura da soja (*Glycine max* (L) Merrill) é atacada por duas espécies do fungo do gênero *Phakopsora*, a causadora da Ferrugem americana (*Phakopsora meibomiae*), e a causadora da Ferrugem asiática (*Phakopsora pachyrhizi*). A diferenciação das duas é possível através da análise de DNA e também da análise da própria morfologia (ONO *et al*, 1992).

A ferrugem americana ocorre naturalmente no Continente Americano. Com uma ampla gama de hospedeiros, o fungo pode infectar naturalmente 42 espécies em 19 gêneros de leguminosas e mais de 18 espécies em 12 gêneros, quando inoculadas artificialmente (HENNEN, 1996). Sua ocorrência se dá desde Porto Rico, no Caribe (VAKILI & BROMFIELD, 1976), até o sul do Estado do Paraná (Ponta Grossa) (DESLANDES, 1979; YORINORI, 1989; YORINORI & DESLANDES, 1984). A ferrugem americana raramente causa perdas. Ela se dá em temperaturas médias abaixo de 25° e umidade relativa elevada, estando localizada na região do Cerrado com mais de 800m de altitude, e também na Região Sul.

A ferrugem asiática, presente na maioria dos países que cultivam a soja na Ásia e Austrália, teve seu primeiro relato em 1902, no Japão, quando ainda era descrita como *Uredo sojae* (PASSINI, 2007). Foi detectada no Hawaii, em 5 de maio de 1994 (KILLGORE, 1996). Seu histórico de disseminação continuou, seguindo para o Continente Africano em 1996, 1998, e 2001 com severos danos (KAWUKI *et al*, 2003; LEVY, 2004; CALDWELL & MACLAREN, 2004; PRETORIUS *et al*, 2001), e no Continente Americano em 1979 (DESLANDES, 1979). No Paraná, sua primeira constatação deu-se por Jaccoud Filho *et al* (2001), na região dos Campos Gerais, onde vinha sendo registrada desde 1998/1999, e então a doença atingiu nível epidêmico em 2000/2001. Yorinori *et al* (2002), e constatou a epidemia na região dos Oeste do Paraná e no Paraguai na safra 2000/2001.

A importância da ferrugem asiática pode ser avaliada pela sua rápida expansão e pelas perdas que causa (YORINORI *et al*, 2003; YORINORI, 2004). É uma das doenças mais severas que incide na cultura da soja, com danos variando de 10% a 90% nas diversas regiões geográficas onde foi relatada (SINCLAIR; HARTMAN, 1999; YORINORI *et al*, 2005).

Em 2001 a estimativa da área afetada no Brasil e no Paraguai era de 10.000 ha. Na safra 2001/02, a doença havia se expandido para quase toda região produtora de soja do Paraguai e em cerca de 60% do Brasil (YORINORI *et al*, 2003). No Brasil, as perdas estimadas nessa safra foram de 569,2 mil toneladas (US\$125,5 milhões; US\$220,50/t) (YORINORI *et al*, 2003). Na safra 2002/03 a ferrugem atingiu mais de 90% da área de

produção do Brasil, causando perdas estimadas em mais de 3,3 milhões de toneladas ou o equivalente a US\$737,4 milhões (US\$223,50/t) (YORINORI *et al*, 2003). Na safra 2003/04, as perdas estimadas chegaram a 4,6 milhões de toneladas, isto é, o equivalente a mais de US\$1,2 bilhão (a US\$260,80/t) (YORINORI, 2004). Deste modo, observa-se que o total de perdas de grãos atribuídas à ferrugem, no Brasil, no período de 2001/02 a 2003/04, período inicial da doença no país, atingiram mais de 8,5 milhões de toneladas ou o equivalente a US\$2,06 bilhões. Na safra 2003/04, a única região do Brasil onde a doença não foi registrada foi o estado de Roraima, que fica no Hemisfério Norte.

O custo da ferrugem asiática no Brasil, desde 2002, com as primeiras epidemias severas até a safra de 2011/12, foi estimado em aproximadamente US\$ 19 bilhões, incluindo as perdas em produção, arrecadação e o custo com o controle dessa doença, (CONSÓRCIO ANTIFERRUGEM, 2012).

Na safra 2012/2013, de acordo com dados da Embrapa, os custos de controle da doença somaram US\$ 1,94 bilhões. Na safra anterior, o custo ferrugem (soma das perdas com os custos de controle) ficou em US\$ 1,73 bilhões, resultado de US\$ 1,54 bi de gastos com o controle mais US\$ 191,6 milhões em perdas (363,5 mil toneladas). No total, até o início de 2014, a ferrugem já custou cerca de US\$ 21 bilhões para o Brasil, com custo médio ao redor de US\$ 2 bilhões por safra nos últimos anos (SOCIEDADE NACIONAL..., 2014)

Sintomas e Diagnóstico

A ferrugem asiática se caracteriza inicialmente com minúsculos pontos (1 a 2 mm de diâmetro) de coloração esverdeada a cinza esverdeada, mais escura que as demais áreas, nas folhas inferiores da planta (Figura 3), progredindo para marrom escuro e marrom avermelhado (BROMFIELD *et al*, 1980).


Figura 3 - Sintomas iniciais de ferrugem asiática na face abaxial da folha de soja



Fonte: AGROLINK, 2014.

Posteriormente, formam-se protuberâncias, chamadas uredias (pústulas que contém os uredósporos), que se apresentam como pequenas saliências na lesão (BROMFIELD *et al*, 1980) (Figura 4).

Figura 4 - Pústulas de *Phakopsora pachyrhizi* na face inferior da folha de soja



Fonte: AGROLINK, 2014.

As lesões podem atingir 2 a 5 mm de diâmetro. Também podem se apresentar nos pecíolos, vagens e caules. As uredias vão adquirindo cor castanho clara a castanho escura, abrem-se em minúsculos poros, por onde são liberado os uredósporos (Figura 5).

Figura 5 - Uredias com poros abertos de *Phakopsora pachyrhizi*



Fonte: SISTEMA DE ALERTA, 2014.

Os uredósporos, de coloração inicial cristalina, tornam-se bege e acumulam-se ao redor dos poros ou são carregados pelo vento.

À medida que prossegue a esporulação, o tecido da folha ao redor das primeiras uredias, tornam-se castanho clara a castanho-avermelhada, ficando facilmente visíveis em ambas as faces da folha.

A ferrugem asiática é uma das doenças de maior importância da cultura da soja na atualidade, pelo grande potencial de perdas na produtividade. Plantas infectadas apresentam desfolha precoce, comprometendo a formação e o enchimento de vagens, reduzindo o peso final dos grãos (BROMFIELD, 1980) (Figura 6).

Figura 6 - Danos decorrentes da infecção de *Phakopsora pachyrhizi*



Fonte: GRUPO CULTIVAR, 2014.

Em casos de ataques severos, as plantas ficam semelhantes a lavouras dessecadas com herbicidas, sofrendo perda de flores e vagens, e deficiência na formação dos grãos. Quanto mais cedo ocorrer a desfolha, menor será o tamanho dos grãos e, consequentemente, menor rendimento e qualidade. O fungo alimenta-se do tecido vivo das plantas, deste modo, em cultivares suscetíveis, as células infectadas morrem somente após ter ocorrido abundante esporulação. Isto faz com que as lesões não sejam facilmente visíveis, no início da infecção (BROMFIELD, 1980).

Uma técnica utilizada para auxiliar no diagnóstico, é olhar uma folha suspeita contra o céu ou outro fundo claro. Uma vez localizado o ponto suspeito (1-2 mm de diâmetro), deve-se observar o ponto escuro pela face inferior (abaxial) da folha com uma lupa de 10x a 30x de aumento, ou sob microscópio estereoscópico, a presença de uredias. No ponto escuro, é possível observar algo como uma minúscula bolha de ferida. É a partir daí que se inicia a frutificação do fungo. Uma conduta que permite observação das uredias a campo, sem o auxílio de lupa de bolso, facilitando sua visualização, é ao olhar a folha contra a luz deve-se fazer com que ela incida com inclinação sobre a face abaxial da folha, de modo a formar a projeção de sombra das uredias (EMBRAPA SOJA, 2014).

Outra técnica com o intuito de facilitar a visualização da presença do fungo nas lesões na parte posterior da folha, é coletar folhas suspeitas de terem a ferrugem, em seguida fechá-las em um saco plástico com um papel úmido, e modo a incubá-las por um período de

12 a 24 horas. Após o período de incubação, será possível observar mais claramente a presença de uredias com o auxílio de uma lente ou colocando a folha sob a luz (CONSÓRCIO ANTIFERRUGEM, 2014).

A caracterização da ferrugem asiática pode atrapalhar no diagnóstico. As lesões doença são semelhantes às de outras três doenças, a mancha parda (*Septoria glycines*) durante a fase reprodutiva, o crestamento bacteriano (*Pseudomonas savastanoi pv. glycinea*) e a pústula bacteriana (*Xanthomonas axonopodis pv. glycines*) durante os estágios iniciais de desenvolvimento (YORINORI, 2004.)

A pústula bacteriana é uma doença de folhas, mas pode atacar pecíolos, hastes e vagens. Seus sintomas se assemelham aos do crestamento bacteriano e aos da ferrugem-asiática, o que comumente causa confusão. São pequenos pontos elevados de cor amarelo-palha, que necrosam em pouco tempo, geralmente com pequeno halo amarelo, que pode alargar-se nas lesões mais velhas. Com a evolução da doença, as manchas, que são irregulares na superfície da folha, aumentam em número e tamanho. Na ferrugem, as uredias que deixaram de esporular apresentam as pústulas com os poros abertos, o que permite distinguir da pústula bacteriana (GRUPO CULTIVAR, 2014).

O crestamento bacteriano também é comum em folhas, podendo infestar também hastes, pecíolos e vagens, como na pústula bacteriana. Surge como pequenas manchas, translúcidas, circundadas por um halo verde-amarelado, que depois necrosam, formando extensas áreas de tecido morto, entre as nervuras secundárias. Atrás da folha, as manchas são quase negras, com uma película brilhante nas horas úmidas da manhã (EMBRAPA SOJA, 2014).

A mancha parda, suas lesões iniciais formam um halo amarelo ao redor da lesão necrótica, que é angular e castanho-avermelhada, o que confunde com as lesões da ferrugem (EMBRAPA SOJA, 2014).

Em todos os casos, as folhas infectadas amarelam, secam e caem prematuramente.

Ciclo da Ferrugem Asiática

Estima-se que uma geração inicial pode esporular durante até 15 semanas, advindo de uma infecção primária, mesmo havendo condição de baixa umidade. Se durante a estação houver condições para uma reinfecção mesmo que esporadicamente, pelo fato de a ferrugem asiática possuir diversos hospedeiros alternativos (JACCOUD FILHO, *et al*, 2007), há uma

grande quantidade de fontes de inóculos, podendo se tornar potenciais para uma reinfecção. Os esporos da doença são capazes de viajar grandes distâncias, sendo levados e disseminados através do vento, infectando outras áreas também. A Figura 7 mostra o ciclo da doença (AGROLINK, 2014)

Figura 7 - Ciclo da Ferrugem Asiática



Fonte: AGROLINK, 2014.

Manejo e Controle

A ocorrência da ferrugem asiática da soja está diretamente associada às condições climáticas. Temperaturas médias inferiores que 28° C e molhamento foliar de mais de 10 horas favorecem a infecção da planta. Em regiões mais quentes a ocorrência é mais leve, sendo que quando há a infestação não se desenvolve de modo devastador. Já regiões com altitude superior a 700 metros são mais favoráveis à ocorrência da doença, pois suas temperaturas noturnas mais amenas associadas a um maior número de horas de orvalho favorecem o aparecimento da ferrugem. Porém, em regiões mais baixas onde há chuvas bem distribuídas, também há uma maior propensão ao desenvolvimento mais rápido da doença (YORINORI, 2004).

Atualmente não há relatos de cultivares de soja resistentes à ferrugem asiática, pois o fungo tem uma variabilidade muito grande, com inúmeras raças de *Phakopsora pachyrhizi*. Isto faz com que um cultivar dito como resistente, possa facilmente não ser mais. Deste modo, para reduzir o risco de danos, é recomendado o uso de cultivares de ciclo precoce e sementeiras no início da época recomendada, para evitar a maior carga de esporos do fungo que irá iniciar a multiplicação nas primeiras sementeiras, atacando plantas muito jovens, o que aumenta a severidade (YORINORI, 2001).


O diagnóstico precoce também é ferramenta fundamental no controle da ferrugem asiática da soja, devendo ser realizadas frequentes vistorias na lavoura, já que a doença pode atacar em qualquer estágio da cultura. O monitoramento e sua detecção nos estágios iniciais são essenciais para a eficiência no controle químico. Pesquisadores da Embrapa apontam que o monitoramento deve ser intensificado e quase diário, uma vez detectada a ferrugem em região de sementeiras mais tardias (CONSÓRCIO ANTIFERRUGEM, 2012).

O monitoramento e controle de plantas invasoras também é importante, pois a ferrugem infecta em torno de 95 espécies de plantas em mais de 42 gêneros, inclusive daninhas (JACCOUD FILHO, 2007).

Escala Diagramática da Severidade

Godoy *et al* (2006) desenvolveram um estudo sobre a severidade da ferrugem asiática da soja e propuseram uma escala diagramática para os níveis de severidade da doença. A escala proposta apresenta os níveis de 0,6; 2; 7; 18; 42 e 78,5 %, como mostra a Figura 8.

Figura 8 - Escala diagramática para severidade da ferrugem da soja (percentual da área doente da folha)



Fonte: GODOY *et al*, 2006.

Para o presente estudo, as escalas utilizadas foram diferentes. Com o apoio do grupo de Fitopatologia Aplicada do curso de Agronomia da Universidade Estadual de Ponta Grossa, previamente às análises, chegou-se a um consenso de que os níveis deveriam ser distribuídos em um maior número de faixas do que o da escala apresentada, sendo que a quantidade e quais seriam estas faixas foram sendo definidas ao longo das análises. A decisão considerou que o objetivo da pesquisa é o de facilitar o constante monitoramento da lavoura, isto é, quanto mais níveis houver, maior será o acompanhamento para as variações constantes da evolução da doença nas frequentes varreduras à lavoura, o que poderá facilitar a tomada de decisão quanto ao controle da ferrugem asiática.

Considerando que a ferrugem asiática da soja apresenta sintomas que podem ser reconhecidos visualmente, foi investido em estudos na área de processamento digital de imagens, no intuito de representar a doença computacionalmente.

2.2 Sistemas de Visão Computacional

2.2.1 O processamento Digital de Imagens (PDI)

O processamento digital de imagens vem ganhando espaço em vários campos de aplicações.

“Uma imagem pode ser definida como uma função $f(x, y)$ de duas dimensões, onde x e y são coordenadas planas, e a amplitude de f para cada par de coordenadas é chamado de intensidade [ou tom]...” (GONZALEZ, WOODS & EDDINS, 2004). De modo informal, uma imagem pode ser definida como a representação visual de um objeto.

No início deste século, estudiosos procuravam formas de aprimorar a qualidade de impressão de imagens digitalizadas transmitidas através do sistema Bartlane (sistema de transmissão de imagens por cabo submarino entre Londres e Nova Iorque). Os primeiros sistemas Bartlane, no início da década de 20, codificavam uma imagem em cinco níveis de intensidade distintos. Em 1929, esta capacidade expandiu-se para 15 níveis. Em paralelo, um método aprimorado de revelação de filmes por feixes de luz modulados por uma fita que continha informações codificadas sobre a imagem era desenvolvido.

Entretanto, foi com o advento dos primeiros computadores digitais e de grande porte, e com o início do programa espacial norte-americano que houve um significativo impulsionamento para o processamento de imagens. Foi no *Jet Propulsion Laboratory* (Pasadena, California - EUA), em 1964, que teve início o uso de técnicas computacionais de

aprimoramento de imagens, quando computadores processavam imagens da lua transmitidas por uma sonda, com o objetivo de corrigir distorções inerentes à câmera de TV acoplada à sonda. Deste modo, tais técnicas serviram de base para métodos aprimorados de realce e restauração de imagens de outros programas espaciais posteriores, como as expedições tripuladas da série Apollo, por exemplo.

Os estudos em processamento de imagens vêm crescendo expressivamente nas últimas décadas, desde 1964 até os dias atuais. Sabe-se que suas aplicações permeiam quase todos os ramos da atividade humana (MARQUES FILHO & VIEIRA NETO, 1999), como nas ciências dos materiais (ALBUQUERQUE *et al*, 2007), no urbanismo (BOTELHO & CENTENO, 2005), na saúde (VERONEZI *et al*, 2011), na medicina como por exemplo no monitoramento *on-line* de parâmetros respiratórios de pacientes com Esclerose Lateral Amiotrófica (ELA) (SILVA *et al*, 2013), entre outras.

Na agricultura, o processamento digital está presente, como exemplos, no mapeamento de áreas plantadas (JOHANN *et al*, 2012), no reconhecimento de patologias em culturas (PIRES *et al*, 2009), análises de uso do solo (OLIVEIRA BATISTA & LEAL SANTOS, 2011), detecção de queimadas (GONÇALVES *et al*, 2012), até mesmo em controle de qualidade de frutas e verduras (SALDAÑA *et al*, 2013).

2.2.2 O sistema Visual Humano e o PDI

O sistema visual humano é adaptativo e capaz de reconhecer características de um mesmo objeto ou imagem em diferentes condições, como por exemplo, luminosidade, posição e cor variadas (GONZALEZ & WOODS, 2010).

Dentre as características relevantes do sistema visual humano para o projeto de sistemas de visão artificial, destaca-se a capacidade de adaptação do olho humano a uma variedade de intensidade luminosa e a relação entre estes níveis de intensidade luminosa presentes na cena e a sensação subjetiva de brilho. O sistema visual não pode operar simultaneamente sobre esta faixa de variação de intensidade luminosa e brilho, assim, esta variação é obtida por meio do excursionamento do olho ao longo de toda esta mesma faixa através de adaptações em sua sensibilidade global, um fenômeno conhecido como adaptação de brilho. A faixa total de valores de intensidade que o olho pode discriminar simultaneamente é comparativamente pequena em relação à faixa total de adaptação (GONZALEZ & WOODS, 2010).

O sistema de visão artificial tenta implementar a mesma capacidade humana, entretanto, para Marques Filho & Vieira Neto (1999), há desafios pertinentes, como obter uma base de dados tão rica quanto o sistema visual humano, sua alta velocidade e o principal, a capacidade de trabalhar em situações diversas.


Marques Filho & Vieira Neto (1999) acreditam que os avanços tecnológicos em capacidade de armazenamento e rapidez no processamento tornam mais próximos os desafios referentes à base de dados e a alta velocidade inerentes à capacidade visual humana, sendo que o principal foco continua sendo a capacidade de trabalhar em diferentes condições. Pode-se analisar o exemplo de que o sistema visual humano é capaz de reconhecer um parente em meio a varias outras pessoas, independentemente se ele está usando óculos, chapéu, se deixou a barba crescer ou pintou os cabelos, ainda podendo ser este reconhecimento apenas de perfil e com uma luminosidade reduzida.

2.2.3 Etapas do Processamento Digital de Imagens

Para se realizar um processamento digital em uma imagem, é necessário passar por uma série de etapas, para que a imagem possa ser transformada e gere a saída desejada. Assim sendo, pode-se dizer que estas etapas são fundamentais para o processamento de uma imagem (GONZALEZ & WOODS, 2010).

A Figura 9 ilustra tais etapas e o relacionamento entre elas:

Figura 9 - Um Sistema de Visão Artificial (SVA) e suas principais etapas



Fonte: MARQUES FILHO & VIEIRA NETO (1999).

A seguir, cada uma das etapas são explanadas com o intuito de melhorar o entendimento (MARQUES FILHO & VIEIRA NETO, 1999; GONZALEZ & WOODS, 2010):

- **Aquisição:** refere-se ao primeiro passo no processo de PDI. Tem como função converter uma imagem em uma representação numérica, adequada para o processamento digital subsequente, no caso uma imagem binária com representação de 0's e 1's, e refere-se ao processo pelo qual a imagem é submetida para sua captura.
- **Pré-processamento:** envolve procedimentos normalmente expressos sob a forma algorítmica. A imagem resultante do passo anterior pode apresentar diversas imperfeições como pixels ruidosos, contraste e/ou brilho inadequado, caracteres interrompidos, etc. A função da etapa de pré-processamento é aprimorar a qualidade da imagem para o uso nas etapas subsequentes, e seu resultado é uma imagem digitalizada de melhor qualidade que a original.

- Segmentação: o objetivo dessa etapa é dividir uma imagem, localizando objetos significativos, isto é, objetos de interesse que a compõem. Aparentemente simples de se descrever, a segmentação é uma das tarefas mais difíceis de implementar.
- Extração de Características: esta, talvez a etapa mais importante para o efetivo reconhecimento de padrões, refere-se a extrair informações da imagem através de descritores capazes de caracterizar a região em questão.
- Reconhecimento e Interpretação: por fim, esta etapa faz a rotulação e atribuição de significado aos objetos reconhecidos na etapa anterior.

O domínio do problema é modelado de acordo com o contexto do mesmo, sendo que o resultado também está condicionado ao objetivo do processamento de imagem do problema em questão (por exemplo, definir se o problema necessita que a imagem seja representada por textura ou formas). Todas as etapas estão ligadas a uma base de dados, pois se pressupõe a existência de um conhecimento sobre o problema a ser resolvido. Vale ressaltar que nem todos os sistemas de visão artificial passam por todas estas etapas, pois depende da modelagem e escopo do problema em questão, cujo tamanho e complexidade podem variar enormemente (GONZALEZ & WOODS, 2010).

Para auxiliar na execução de tarefas visuais, existe, entre outras ferramentas, a *OpenCv* (*Open Source Computer Vision Library*), que é uma biblioteca projetada para aplicações de visão computacional. Ela fornece a infraestrutura adequada para o tratamento e análise de imagens. Deste modo, auxilia na realização de funções visuais, contribuindo para o melhor funcionamento das demais etapas existentes em aplicações que necessitem de manipulação de imagens. Possui versões para as linguagens de programação Java (JAVA, 2015), C (OPEN STD, 2015), C++ (OPEN STD, 2015) e Pythom (PYTHOM, 2015). Há também um SDK (Software Development Kit ou Kit de Desenvolvimento de Software em tradução livre) para a plataforma *Android* (ANDROID, 2014; OPENCV, 2013).

2.2.3.1 Extração de Características

Matematicamente falando, uma imagem é uma função bidimensional $f(x,y)$ onde x e y são coordenadas planas, e a amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade ou nível de cinza da imagem no referido ponto. Quando (x,y) e a amplitude de

f fazem parte de um conjunto de valores finitos, ou discretos, a imagem é chamada de imagem digital (GONZALEZ & WOODS, 2002).

Em outras palavras, cada elemento desta matriz corresponde à intensidade ou nível de cinza $f(x,y)$ em um determinado ponto da imagem. Estes elementos de imagens digitais são os pixels, que possuem uma intensidade que representa uma cor neste ponto da imagem. Nas imagens em preto e branco (binárias), os valores dos pixels ficam entre 0 e 1. Já para imagens compostas em tons de cinza, estes valores podem variar de 0 a 255. Por fim, para imagens coloridas, o valor de um pixel é representado por três valores, que vão de 0 a 255 cada um.

Após a aquisição, o pré-processamento busca melhorar a imagem antes de ela ser processada, com tratamento de ruídos, realce, segmentação, entre outros métodos. O pré-processamento não é uma etapa obrigatória do processamento, mas pode melhorar consideravelmente o resultado final (PONTI JR, 2012).

Os descritores de imagens são utilizados para caracterizar imagens em aplicações distintas. Cada descritor objetiva capturar certas características presentes nas imagens, como por exemplo, cor, textura e forma. A escolha da categoria do descritor e de quais descritores efetivamente serão usados, varia de acordo com o objetivo do estudo/aplicação em questão (PENATTI, VALLE & TORRES, 2012).

As características podem ser gerais ou de domínio específico. As denominadas gerais são comuns em qualquer imagem, tais como cor, textura e forma, bem como uma combinação destas. Os descritores baseados em cor, textura e em forma são denominadas de características primitivas (ARAÚJO & OLIVEIRA, 2011). Já as de domínio específico, são aquelas que dependem do contexto da própria aplicação em questão. Por exemplo, sistemas referentes a impressões digitais e faces humanas necessitam a utilização de características de domínio específico (ARAÚJO & OLIVEIRA, 2011).

Dá-se o nome de vetor de características as características que são extraídas de uma imagem. É necessário escolher as propriedades que serão extraídas da imagem em questão, de modo que elas sejam significativamente representativas ao passo que também não gerem um alto custo computacional na criação do vetor, bem como na recuperação do mesmo, para posterior utilização na classificação da imagem (ESCOBAR & PONTI JR, 2012).

Em aplicações como sistemas embarcados e computação móvel, é importante utilizar descritores compactos, utilizando as informações que melhor caracterizem as imagens armazenadas em menor quantidade de dados possível, no intuito de não onerar o processo computacional. Essas características são fundamentais para permitir processamento local e em

tempo real, e viabilizar a transmissão via rede sem fio com poucos pacotes (ESCOBAR & PONTI JR, 2012).

Cor

A cor pode ser definida como um fenômeno perceptual da luz quando incide e é refletida (OSHIRO E GOLDSCHMIDT, 2008). Em sistemas de recuperação de imagens baseadas em conteúdo, a cor é uma das características mais utilizadas (TORRES & FALCÃO, 2006) por ser relativamente independente quanto ao tamanho, orientação e resolução da imagem. Para Bender (2003), é uma característica computacionalmente menos cara se comparada aos demais descritores. As cores são representadas através de uma estrutura denominada histograma de cores, que representa a distribuição global de cores. Pode-se também considerar apenas uma determinada parte de interesse na imagem.


No entendimento de cor, devem-se observar dois conceitos importantes, a luminância e a cromaticidade. A luminância refere-se à quantidade das cores pretas e brancas presentes em uma imagem. Para o cérebro humano, é como a quantidade de cinza (ou brilho) presente na cor. Já a cromaticidade informa a respeito da tonalidade de uma cor. É a frequência dominante do raio de luz. A combinação destes dois conceitos, em diferentes proporções, permite ao cérebro perceber o espectro de cores visível em uma determinada imagem ou cena. Para representar as cores existem modelos ou sistemas de cores (GONZALEZ & WOODS, 2010), como o sistema RGB (“*red, green, blue*” ou vermelho, verde e azul), o CMY (“*cyan, magenta, yellow*” ou ciano, magenta e amarelo), o HSI (“*hue, saturation, intensity*” ou matiz, saturação e intensidade), YIQ (luminância, em-fase, quadratura), LAB (luminosidade, verde-vermelho, azul-amarelo) e MTM.

O sistema *Red, Green, Blue* é um sistema de representação de cor (DEL BIMBO, 1999) aditivo (cor produzida a partir da emissão de luz) e se baseia na teoria dos três estímulos proposta por Young-Helmholtz (SCHWARTZ, 1999; GEGENFURTNER e SHARPE, 2000). A teoria diz que a percepção da cor pelo olho humano se dá através do estímulo de três pigmentos visuais presentes nos cones da retina ocular, que possuem sensibilidades para alguns comprimentos de onda, como os que representam a cor vermelha, a cor verde e a cor azul.

O sistema RGB é comumente utilizado na reprodução de cores em dispositivos eletrônicos como monitores de TV e computador, projetores, *scanners*, câmeras digitais e

fotografia tradicional. A Figura 10 mostra o cubo com eixos RGB, que representa o sistema e cor.

Figura 10 - Cubo representando o espaço de cores RGB



Fonte: GONZALEZ & WOODS, 1992.

Textura

Para Tuceryan & Jain, 1993 *apud* Castañón, 2003, não existe uma definição clara de textura, mas concordam em defini-la como as mudanças na intensidade da imagem que formam determinados padrões repetitivos. Assim, a textura está ligada a propriedades como suavidade, rugosidade e regularidade.

Gonzalez e Woods (2002) citam a existência de três principais abordagens para se descrever texturas: a abordagem espectral, estrutural e estatística.

Pode-se classificar a abordagem estatística em como sendo de primeira ordem, onde é possível extrair características através de histogramas de primeira ordem (por exemplo, média, desvio-padrão, coeficiente de assimetria e de curtose), e de segunda ordem, onde são utilizados histogramas de segunda ordem permitindo uma diferenciação espacial da distribuição de níveis de cinza em uma imagem ou textura (GONZALEZ & WOODS, 2002).

As abordagens estatísticas consideram a distribuição dos tons de cinza presentes na imagem e o relacionamento entre eles (OSHIRO & GOLDSCHMIDT, 2008). Estes autores afirmam que, para trabalhar com os principais descritores de textura presentes nessa abordagem, é necessário armazenar as características extraídas da imagem em uma estrutura denominada matriz de coocorrência de níveis de cinza. A matriz de coocorrência de níveis de cinza (*Grey Level Co-Occurrence Matrix*) é uma abordagem estatística de segunda ordem.

Leva em consideração a posição de pixels que possuem níveis de cinza. Uma matriz de coocorrência é uma tabulação sobre o número de combinações distintas de valores de intensidade que ocorrem em uma imagem (SCHWARTZ & PEDRINI, 2003).

Sendo assim, a princípio, para utilizar essas matrizes, é preciso que a imagem apresente somente tons de cinza, embora haja estudos estendendo a utilização da matriz de coocorrência a imagens coloridas (TANNÚS *et al*, 2010). O tamanho de uma matriz de coocorrência é igual ao quadrado do número de tons de cinza existentes na imagem. Os elementos da matriz são gerados a partir de uma varredura que verifica as transições entre os tons de cinza dos pixels vizinhos (NASCIMENTO, 2003).

A varredura compara dois pixels, um chamado de pixel de referência e o outro pixel vizinho (OSHIRO E GOLDSCHMIDT, 2008). Assim, o elemento $P(m, n)$ (onde m é linha e n é coluna da matriz) da matriz de coocorrência representa o número de transições entre os níveis de cinza m e n presentes na textura. Em outras palavras, pode-se exemplificar que na posição $P(1,2)$ da matriz de coocorrência, será armazenada a quantidade de transições encontradas entre um pixel e seu vizinho nas quais o pixel de referência apresenta intensidade de cinza igual a 1 e o pixel vizinho apresenta intensidade igual a 2. A Tabela 1 ilustra uma matriz de coocorrência para quatro níveis de cinza, onde cada elemento da matriz diz respeito às transições de níveis de cinza. Depois da contagem, é preciso normalizar a matriz (dividindo cada elemento pela soma de todos eles).

Tabela 1 - Matriz de Coocorrência

	0	1	2	3
0	$P(0,0)$	$P(0,1)$	$P(0,2)$	$P(0,3)$
1	$P(1,0)$	$P(1,1)$	$P(1,2)$	$P(1,3)$
2	$P(2,0)$	$P(2,1)$	$P(2,2)$	$P(2,3)$
3	$P(3,0)$	$P(3,1)$	$P(3,2)$	$P(3,3)$

Fonte: OSHIRO E GOLDSCHMIDT, 2008.

Haralick *et al* (1973) propuseram quatorze descritores estatísticos para representar as características de textura presentes em uma imagem, a saber: Segundo Momento Angular, Contraste, Correlação, Variância, Momento de Diferença Inverso, Média da Soma, Variância da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, Medidas de Informação da Correlação (2 propriedades) e Coeficiente de Correlação Máximo.

Tais descritores são extraídos a partir de uma matriz de coocorrência de níveis de cinza normalizada. Posteriormente, Baraldi e Parmiggiani (1995) estudaram algumas das características de Haralick investigando a que tipo de percepção visual as características estudadas se associavam, e então apontaram para seis delas como sendo as mais relevantes. São o segundo momento, angular, a entropia, o contraste, a variância, a correlação e a homogeneidade, mostradas no Quadro 1.

Foram escolhidos estes descritores da abordagem estatística para a realização do trabalho, devido ao bom embasamento teórico encontrado na literatura, e bem como ao baixo custo computacional que apresenta, face ao propósito de processamento local via *smartphone*, em se comparando com descritores de textura mais novos na literatura, como LPQ (Local Phase Quantization) (AHONEN *et al.*, 2008).

Quadro 1 - Descritores de Textura baseados nas matrizes de coocorrência

DESCRIPTOR	SIGNIFICADO	FÓRMULA MATEMÁTICA
Segundo Momento Angular	Indica a uniformidade da textura (quantidade de repetições para os pares de pixels presentes na imagem). Apresenta valores mais altos se a imagem está ordenada.	$SMA = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j)^2$
Entropia	Mede a desordem da imagem. Esse descritor está relacionado de forma inversa ao segundo momento angular.	$E = - \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \log(P(i, j)) P(i, j)$
Contraste	Estimativa que indica a variação entre os tons de cinza para cada par de pixels vizinhos presentes na imagem. Valores presentes na diagonal da matriz de coocorrência indicam pouco contraste.	$C = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j)(i - j)^2$
Variância	Mede a heterogeneidade da textura. Quanto maior a diferença entre os valores dos tons de cinza e sua média, maior a variância.	$\sigma_x^2 = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j)(x - \mu_x)^2$
Correlação	Indica a dependência linear entre os níveis de cinza existentes na imagem, ou seja, o quão um pixel está correlacionado ao pixel vizinho. Esses valores variam na faixa de -1 a 1.	$C = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i, j) \left[\frac{(i - \mu_i)(j - \mu_j)}{(S_i)(S_j)} \right]$
Homogeneidade	Como o próprio nome sugere, mede a homogeneidade da textura presente em uma imagem. Esse descritor está relacionado de forma inversa ao contraste, ou seja, apresenta valores pequenos quando há baixa variação entre os níveis de cinza da imagem.	$H = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{P(i, j)}{1 + (i - j)^2}$

Fonte: HARALICK *et al*, 1973; NASCIMENTO, 2003 *apud* ARAÚJO & OLIVEIRA, 2011; ITO *et al*, 2009 *apud* ARAÚJO & OLIVEIRA, 2011.

2.2.3.2 Filtragem da Imagem

Na etapa de pré-processamento da imagem, antes da realização da extração de características, é possível fazer determinadas alterações nas imagens visando sua melhoria. Operações de filtragem são comumente utilizadas. As operações realizadas nesta etapa de pré-processamento não são obrigatórias, incluindo a filtragem, entretanto, dependendo das imagens e do contexto, a utilização destes recursos pode melhorar consideravelmente a extração das características relevantes das imagens, e por consequência o próprio reconhecimento dos padrões feito posteriormente (MARQUES FILHO & VIEIRA NETO, 1999).

As técnicas de filtragem são transformações que ocorrem na imagem pixel a pixel. Elas consideram o valor do nível de cinza de um determinado pixel e também o valor dos níveis de cinza dos pixels vizinhos, isto é, o novo nível de cinza que um ponto P qualquer receberá após um filtro, dependerá do seu próprio nível de cinza original e o de outros pontos considerados como vizinhança de P, o que em geral significa que os pontos mais próximos contribuem mais para definir este novo valor. Consiste na aplicação de técnicas de transformação com operadores e máscaras (matrizes numéricas) com o objetivo de corrigir, suavizar ou realçar determinadas características de uma imagem dentro de uma aplicação específica. É importante contextualizar o conceito de correção, que é a remoção de características indesejáveis na imagem, e o de melhoria ou realce, que é a acentuação de características (MARQUES FILHO & VIEIRA NETO; GONZALEZ & WOODS, 2010).


Existem dois domínios em que podem ser aplicadas as técnicas de filtragem. São o domínio espacial e o domínio espectral. No domínio espacial, a filtragem empregada opera diretamente sobre os pixels da imagem na sua forma original, normalmente utilizando operações de convolução com máscaras. Este procedimento de utilização de máscaras no domínio espacial é chamado de filtragem espacial e as máscaras são chamadas de filtros espaciais (GONZALEZ & WOODS, 2010).

No contexto matemático para processamento digital de imagens, tem-se que convolução é o tratamento de uma matriz por outra, chamada “núcleo” (kernel). O filtro de matriz de convolução usa uma matriz primária, que é a imagem que se deseja efetuar o tratamento. Esta imagem primária é tida como uma coleção bidimensional de pixels em coordenadas retangulares. O núcleo a ser usado para realizar as transformações depende do efeito que se espera, como corrigir ou suavizar a imagem. O filtro então passa sucessivamente, da esquerda para a direita e de cima para baixo, todos os pixels da área de

ação do núcleo, multiplicando o valor de cada um deles pelo valor correspondente do núcleo, posteriormente somando os resultados e substituindo os valores (GONZALES & WOODS, 2010; GOMES, 1995; PEDRINI & SCHWARTZ, 2008).

No domínio da frequência, a imagem é transformada do domínio espacial para o da frequência (transformada de Fourier). Assim, as operações de filtragem são realizadas nessa imagem, posteriormente realiza-se o processo inverso, onde a imagem no domínio da frequência é transformada novamente para o domínio espacial. A transformada de Fourier faz com que a imagem seja descrita e visualizada em frequências, onde a interpretação de frequência em imagens é feita da seguinte forma: áreas da imagem sem grandes variações de cor representam zonas de baixa frequência, já áreas da imagem com texturas muito densas representam zonas de alta frequência. A Figura 11 mostra uma imagem em domínio de espaço, isto é, a imagem original, e ao lado a mesma imagem de modo espectral, após passar pela transformada de Fourier (GONZALEZ & WOODS, 2010).

Figura 11 - Baboon e seu espectro de Fourier



Fonte: CONCI *et al*, 2008.

No que se refere aos filtros, existem dois tipos, os lineares e os não lineares. Ambos se baseiam na vizinhança. Os filtros lineares suavizam e realçam detalhes da imagem e minimizam efeitos de ruído, sem alterar o nível médio de cinza da imagem. Eles calculam o valor resultante de cada pixel como uma combinação linear dos níveis de cinza em uma vizinhança local do pixel na imagem original. Já os filtros não-lineares não apresentam uma combinação linear e não possuem compromisso de manterem o nível médio de cinza da imagem original. Eles minimizam/realçam ruídos e suavizam/realçam bordas, alterando a

média da imagem, sendo os principais os operadores para detecção de bordas e os filtros morfológicos (GONZALES & WOODS, 2010; GOMES, 1995).

Os filtros tanto lineares quanto não lineares podem ser classificados ainda, entre outros, em filtros passa-baixa e passa-alta (GONZALES & WOODS, 2010; GOMES, 1995).

Os filtros passa-baixa (de suavização) permitem a passagem de baixas frequências, eliminando as frequências maiores que a frequência de corte. Suaviza a imagem atenuando as altas frequências, que correspondem às transições abruptas, como bordas. Minimizam ruídos e apresentam o efeito de borramento da imagem (GONZALES & WOODS, 2010; GOMES, 1995).

Os filtros passa-alta (de aguçamento e detecção de bordas) permitem a passagem de altas frequências, eliminando as frequências menores que a frequência de corte. Realçam detalhes de modo que as transições entre regiões diferentes tornam-se mais nítidas. Podem enfatizar certas características presentes na imagem, como bordas, linhas curvas ou manchas, mas enfatizam o ruído existente na imagem (GONZALES & WOODS, 2010; GOMES, 1995; MARQUES FILHO & VIEIRA NETO, 1999).

Na filtragem linear do domínio espacial, pode-se verificar entre outros, como filtros de suavização (PEDRINI & SCHWARTZ, 2008; GONZALEZ & WOODS, 2010; GOMES, 1995):

- Filtro de média;
- Filtro de média ponderada;
- Filtro gaussiano;
- Filtro bilateral

Já entre os filtros não lineares, pode-se citar (PEDRINI & SCHWARTZ, 2008; GONZALEZ & WOODS, 2010; GOMES, 1995):

- Filtro da mediana (suavização);
- Mediana ponderada (suavização);
- Moda (suavização);
- *Roberts* (detector de bordas);
- *Sobel* (detector de bordas);
- *Prewit* (detector de bordas);
- *Canny* (detector de bordas).

Nos filtros não lineares, como já mencionado, seus principais operadores são para detecção de bordas e os filtros morfológicos. Como exemplos de filtros morfológicos, pode-se citar (PEDRINI & SCHWARTZ, 2008; GONZALEZ & WOODS, 2010; GOMES, 1995):

- Dilatação: provoca efeitos de dilatação das partes escuras da imagem (baixos níveis de cinza), gerando imagens mais claras, fechando pequenos buracos;
- Erosão: provoca efeitos de erosão das partes claras da imagem (altos níveis de cinza), gerando imagens mais escuras, afinando ou retirando porções que saem do limite;
- Fechamento: elimina baías nos limites das regiões, é obtido pelo encadeamento do filtro de dilatação, seguido pelo de erosão;
- Abertura: promove a abertura de pequenos pontos, é obtida pelo encadeamento do filtro de erosão, seguido pelo de dilatação.

Na filtragem do domínio de frequência também podem ser aplicados a maioria destes filtros do domínio espacial citados anteriormente, entre outros, entretanto, foge ao escopo do estudo.

Vale ressaltar que dentre cada classe de filtros, isto é, filtros para realce, filtros para suavização, filtros para detecção de bordas e filtros de operações morfológicas, atuam com o mesmo objetivo comum à classe, entretanto cada filtro tem suas particularidades, trazendo vantagens e desvantagens no que diz respeito ao efeito visual, que são percebidas empiricamente para cada aplicação distinta especificamente. Deste modo, o procedimento para se chegar ao efeito final desejado é a tentativa das alternativas até se chegar ao filtro ou aos filtros que melhor se adaptem ao problema em questão.

2.3 Inteligência Artificial e Aprendizado de Máquina

Técnicas de Inteligência Artificial (IA), em particular de Aprendizado de Máquina (AM), têm sido utilizadas com sucesso em um grande número de problemas reais, do cotidiano, como por exemplo, com programas para reconhecer pessoas pelo rosto ou pela fala, programas de diagnóstico médico, onde o especialista cede ao programa sua “experiência”, através de um conjunto de sintomas e resultados de exames clínicos, sendo capaz de identificar a enfermidade em questão, programas que fazem análise de dados de vendas de uma loja para, por exemplo, identificar conjuntos de produtos que são frequentemente vendidos em conjunto, recomendar novos produtos a clientes que costumam comprar

produtos semelhantes, agrupar consumidores da loja em grupos com interesses em comum para auxiliar no marketing, entre outros (FACELLI *et al*, 2011).

Mas nem sempre a IA atuou tanto assim em problemas reais. Seu uso se restringia à área teórica, com poucas aplicações em problemas desafiadores, porém com pouco valor prático. A partir da década de 1970 houve uma maior disseminação do uso de técnicas de IA para soluções de problemas reais. Com a crescente complexidade dos problemas, bem como o grande volume de dados gerados é que se tornou evidente a necessidade de técnicas computacionais mais autônomas, capaz de construir por si própria uma hipótese ou função baseado em experiências passadas, e resolver o problema em questão (HAYKIN, 2001).

Por exemplo, a descoberta de uma hipótese no modelo de uma ou mais regras para designar à quais clientes determinadas propagandas devem ser enviadas utilizando por base dados de comprar passadas registradas de cada cliente na base de dados do supermercado. Este processo de indução de uma hipótese a partir da experiência passada chama-se Aprendizado de Máquina (AM) (FACELLI *et al*, 2011).

Um comportamento inteligente está condicionado à capacidade de aprendizado. Em AM, os computadores são programados para aprender com a experiência passada. Para isto, a partir de um conjunto particular de exemplos são obtidas conclusões genéricas, o que se chama indução (RUSSEL & NORVIG, 2004).

AM é uma das áreas da computação que mais tem crescido ao longo dos últimos anos, de modo que constantemente são propostos diferentes algoritmos de AM, bem como aumenta a própria variação natural dos problemas a serem resolvidos. As pesquisas em AM também estão sendo cada vez mais incentivadas nas universidades (RUSSELL, & NORVIG, 2004).

Podem ser citadas algumas aplicações em que houve sucesso no emprego de técnicas de AM, como por exemplo, reconhecimento de palavras faladas, predição de taxas de cura de pacientes com diferentes doenças, detecção de uso fraudulento de cartões de crédito, condução autônoma de automóveis em rodovias, jogos que jogam xadrez de forma semelhante a campeões, diagnóstico do câncer por meio de análise de dados da expressão genética do paciente, entre outros (FACELLI *et al*, 2011).

Os modelos de AM gerados são ainda capazes de lidar com situações não apresentadas durante seu processo de aprendizado, sem precisar de uma nova fase no projeto (FREITAS *et al*, 2010).

Indução de Hipóteses

Em algumas tarefas de aprendizado, é necessário eleger um dos atributos como atributo meta, isto é, um atributo de saída, onde seu resultado será estimado através dos valores dos demais atributos, que são chamados atributos de entrada. Nestes casos, o objetivo do algoritmo de AM é aprender, dado um conjunto de dados de treinamento, um modelo de hipótese que consiga “enxergar” e estabelecer uma relação entre os valores dos atributos de entrada e os valores do atributo de saída (FACELLI *et al*, 2011; RUSSELL & NORVIG, 2004; HAYKIN, 1999).

Assim, uma vez induzida uma hipótese, o que se espera é que ela seja válida para os mesmos objetos do domínio do problema, que não façam parte do conjunto de treinamento. Isto se chama generalização de hipótese. Esta hipótese necessita apresentar uma boa capacidade de generalização para ser útil a novos dados. Entretanto, a hipótese pode também se apresentar em duas outras situações, a primeira, como *overfitting*, o que significa que a hipótese memorizou ou se especializou nos dados de treino, ou também pode ocorrer *underfitting*, isto é, quando a hipótese apresenta uma baixa taxa de acerto mesmo nos dados de treinamento (HAYKIN, 1999).

Uma vez definido o atributo meta na indução de hipóteses, a tarefa de aprendizado, explicada a seguir, é responsável, através de seus respectivos métodos e algoritmos escolhidos, por fazer o algoritmo aprender a relação que existe entre os dados e o atributo meta para utilizar posteriormente com dados novos. (FACELLI *et al*, 2011).

Tarefas de Aprendizado

A tarefa de aprendizado é o processo pelo qual os dados são submetidos para se chegar ao aprendizado em si. As tarefas de aprendizado de um algoritmo de AM podem ser divididas em (FACELLI *et al*, 2011):

- Preditivas: o objetivo é encontrar uma hipótese (modelo) a partir do conjunto de dados de treinamento, que possa ser útil para prever novos dados diferentes, baseando-se nos valores de entrada. Deste modo, todos os objetos devem ter atributos de entrada e saída. Algoritmos preditivos se utilizam de aprendizado supervisionado, isto é, já se conhece os valores de saída dos dados de treinamento.

- Descritivas: o objetivo é explorar ou descrever um conjunto de dados. Neste caso, não são utilizados atributos de saída. Assim, se utilizam do paradigma de aprendizado não supervisionado. Por exemplo, encontrar grupos de objetos semelhantes em um conjunto de dados ou ainda encontrar regras de associação que relacionam um grupo de atributos a outro grupo de atributos são tarefas descritivas.

A Figura 12 apresenta uma hierarquia de aprendizado de acordo com os tipos de tarefas de aprendizado.

Figura 12 - Hierarquia de Aprendizado



Fonte: FACELLI *et al*, 2011.

O aprendizado indutivo está no topo, e representa o processo pelo qual as generalizações são feitas a partir dos dados. Em seguida os tipos de aprendizado preditivo (supervisionado) e descritivo (não supervisionado).

No aprendizado supervisionado, a aprendizagem é feita a partir de exemplos, em que o analista ajuda o sistema a construir o modelo, através da definição das classes e dos exemplos em cada classe. O algoritmo precisa identificar a relação do conjunto de propriedades comuns nos exemplos que lhe são fornecidos. Estando a descrição determinada, é possível formular a regra de classificação que pode ser utilizada para prever a classe de um objeto que não tenha sido considerado no processo de aprendizagem. O aprendizado não supervisionado é realizado com base em observação e descoberta. Não são definidas classes. O algoritmo necessita observar os exemplos e reconhecer os padrões por si próprio. Resulta em um conjunto de descrições de classes, uma para cada classe descoberta na base de dados (RUSSELL & NORVIG, 2004).

Nas tarefas supervisionadas, a distinção é feita pelo tipo de rótulo dos dados, isto é, discreto para classificação, e contínuo para regressão. Já as tarefas descritivas se dividem genericamente em agrupamento (dados agrupados por similaridade), associação (visa encontrar padrões frequentes de associações entre os atributos dos conjuntos de dados) e sumarização (visa encontrar uma descrição simples e compacta para o conjunto de dados) (FACELLI *et al*, 2011).

A seguir, serão explanados conceitos sobre o método de AM Redes Neurais Artificiais, que podem ter seu aprendizado se enquadrando tanto em supervisionado quanto em não supervisionado, dependendo da tarefa de aprendizado e do algoritmo de treinamento escolhidos, de modo que em qualquer aprendizado o objetivo será encontrar padrões de similaridade nos dados.

2.3.1 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são utilizadas para resolver problemas de Inteligência Artificial (IA), e podem ser aplicadas em diversas áreas do conhecimento. Na agricultura, por exemplo, encontra-se sua utilização na análise de dados agrícolas (MATHIAS, 2006), na classificação automática de cultivares (RAMOS, 2003), e no auxílio à tomada de decisão (BRESSAN, 2004).

No Aprendizado de Máquina, dentro das tarefas de aprendizado preditivas, há algumas divisões dos modelos, que os diferenciam de acordo com o modo como realizam a predição. São estes: Métodos baseados em Distância (como o Algoritmo do Vizinho Mais Próximo), Métodos Probabilísticos (como Redes Bayesianas), Modelos baseados em Procura (como Árvores de Decisão) e Métodos baseados em Otimização (como Redes Neurais Artificiais e Máquinas de Vetores de Suporte) (FACELLI *et al*, 2011).

Nos métodos baseados em otimização, algumas técnicas realizam a busca pela hipótese que descreve os dados recorrendo à otimização de alguma função específica. Assim, o objetivo do problema de aprendizado consiste em minimizar ou maximizar uma função objetivo. Para problemas supervisionados, em geral, o rótulo dos objetos é considerado de alguma maneira na formulação do problema realizada (HAYKIN, 2001).

As Redes Neurais Artificiais também se valem deste processo de otimização. O algoritmo envolve uma regra de correção de erros, na qual se recorre à otimização de uma função quadrática do erro entre as respostas da RNA e os rótulos dos exemplos. (FACELLI *et al*, 2011; HAYKIN, 2001)

A motivação para estudos em RNA's dá-se desde o início pelo vislumbamento de como o cérebro humano processa as informações. Ele é capaz de aprender através da organização que realiza em seus neurônios. No dia-a-dia, os seres humanos realizam diversas tarefas que necessitam de atenção simultânea à diferentes acontecimentos, bem como o processamento destas informações variadas, e assim, após uma análise rápida, são capazes de tomar decisões as determinadas situações. Tarefas simples para os seres humanos, como pegar um objeto, identifica-lo em meio a outros, ou simplesmente caminhar, são notadamente atividades difíceis de serem ensinadas à robôs. O cérebro humano, composto por uma complexa estrutura biológica, é o responsável por executar tais tarefas simples, ou complexas, de modo a realizar um processamento também bastante complexo e produzir as respostas necessárias (HAYKIN, 2001; RUSSELL & NORVIG, 2004).

Deste modo, as redes neurais visam simular a capacidade de aprendizado apresentada pelo cérebro humano na aquisição de conhecimento.

Para Facelli *et al* (2011), as RNA's são sistemas computacionais distribuídos compostos por unidades de processamento simples, densamente interconectadas.

Haikyn (2001) define uma RNA como:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:


- 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.*

De modo geral, as unidades de uma RNA, conhecidas como neurônios artificiais, trabalham computando funções matemáticas. As unidades são organizadas em uma ou mais camadas na arquitetura da rede, e interligadas por um grande número de conexões, onde, na maioria dos modelos de arquitetura, simulam as sinapses biológicas. A simulação das sinapses biológicas ocorre, pois todas as conexões existentes possuem pesos associados, que ponderam a entrada recebida por cada neurônio da rede (FACELLI *et al*, 2011). Os pesos têm seus valores ajustados em um processo de aprendizado e codificam o conhecimento adquirido pela rede (BRAGA *et al*, 2007).

O sistema nervoso é um conjunto complexo de células que atuam de forma fundamental para o funcionamento e comportamento de um ser vivo. A unidade fundamental do sistema nervoso é o neurônio, cujos principais componentes são: dendritos, corpo celular e

axônio. Os dentritos são responsáveis pela recepção de estímulos nervosos advindos de outros neurônios ou mesmo do ambiente. Estes estímulos são enviados para o corpo celular ou soma, que os coleta, combina e processa. Assim, o soma gera um novo impulso que é enviado para o axônio, cuja função é conduzir os impulsos elétricos produzidos no corpo celular até outro local mais distante. O sinal do neurônio flui então da esquerda para a direita, isto é, dos dentritos para o corpo celular, então para o axônio. Sinapse é o nome que se dá para o contato existente entre a terminação de um axônio e o dentrito de outro neurônio (HAYKIN, 1999). Um neurônio biológico simplificado é ilustrado na Figura 13.

Figura 13 - Neurônio biológico simplificado



Fonte: FACELLI *et al*, 2011.


Neste contexto, pode-se caracterizar uma RNA por dois aspectos básicos: a arquitetura e o aprendizado. Por arquitetura, entende-se o tipo, número de unidades de processamento e forma de conexão. Por aprendizado entende-se as regras utilizadas para o ajuste dos pesos da rede e que informação é utilizada pelas regras.

Arquitetura

O neurônio é a unidade de processamento de uma RNA, peça fundamental para seu funcionamento. A Figura 14 ilustra um modelo simples de neurônio artificial, de modo que é possível observar em comparação ao neurônio biológico, que cada terminal de entrada simula um dentrito, que recebe um valor. Estes valores são ponderados e combinados por meio de

uma função matemática f_a , equivalendo ao processo realizado pelo soma. Por fim, a saída da função é a resposta do neurônio para a entrada (HAYKIN, 1999).


Figura 14 - Neurônio artificial



Fonte: HAYKIN, 1999 *apud* FACELLI *et al* 2011

Uma arquitetura de RNA pode ser organizada em uma ou mais camadas de neurônios. Dá-se o nome de rede multicamadas quando há mais de uma. Quando duas ou mais camadas de neurônios são utilizadas, um neurônio pode receber como entrada a saída de um neurônio da camada anterior, e também pode enviar suas saídas para a entrada de neurônios da camada posterior. A Figura 15 ilustra um exemplo de uma RNA com duas camadas intermediárias (escondidas ou ocultas) de neurônios, recebendo dois valores de entrada, e gerando dois valores de saída na camada de neurônios de saída (HAYKIN, 1999).

Figura 15 - Exemplo de RNA multicamadas típica



Fonte: FACELLI *et al*, 2011.

Aprendizado

A propriedade de maior importância de uma rede neural é sua habilidade de aprender a partir do ambiente em que está inserida, e então melhorar seu processo através da aprendizagem. A rede aprende sobre o ambiente após um processo iterativo de ajustes, de modo que, idealmente, a rede se torna mais instruída sobre seu ambiente após cada iteração do processo de aprendizagem (HAYKIN, 2001).

Para que o modelo da rede neural obtenha um melhor desempenho, que é medido pela acurácia preditiva, existe alguns algoritmos de treinamento, que fazem os ajustes dos parâmetros de uma RNA. Estes algoritmos são formados por um conjunto de regras bem definidas que especificam quando e como deve ser alterado o valor de cada peso (FACELLI *et al*, 2011). Estes algoritmos podem ser divididos em quatro grupos:

- Correção de erros: aprendizado supervisionado; ajusta os pesos para reduzir erros;
- Hebbiano: aprendizado não supervisionado; baseados na regra de Heb, que diz que se dois neurônios estão ativos ao mesmo tempo, deve-se reforçar sua conexão;
- Competitivo: aprendizado não supervisionado; geram uma competição entre neurônios para saber quais serão ajustados;
- Termodinâmico (*Boltzmann*): algoritmos estocásticos baseados em princípios da metalurgia.

O foco deste estudo está no grupo dos algoritmos por correção de erros, utilizado em redes neurais com aprendizado supervisionado.

Redes Perceptron e Adaline

A rede perceptron, desenvolvida por Rosenblatt (1958), foi a primeira rede neural artificial a ser implementada. Esta rede apresenta apenas uma camada de neurônio com um único deste, e embora simples, demonstrou uma boa acurácia preditiva em problemas de classificação. A rede perceptron é treinada por um algoritmo supervisionado de correção de erros, e utiliza função de ativação limiar (HAYKIN, 2001).

Rosenblatt provou anos depois o teorema de convergência da rede, que diz: “*Se é possível classificar um conjunto de entradas linearmente, uma rede perceptron fará essa classificação.*”.

A rede adaline (*Adaptive Linear*) (WIDROW & HOFF, 1960), surgiu na mesma época, sendo que as principais diferenças são que a rede adaline utiliza função de ativação linear, que considera a magnitude do erro para o ajuste dos pesos, utilizando uma regra de ajuste denominada Regra Delta (WIDROW & HOFF, 1960), que usa a diferença entre os valores de saída produzidos e os desejados. A equação para o ajuste é similar, sendo valores de saída definidos contínuos para adaline.

Deste modo, redes adaline são comumente utilizadas em problemas supervisionados de regressão, enquanto que as redes perceptron foram propostas para problemas de classificação (HAYKIN, 2001).

Uma limitação para estas redes de uma camada é o fato de conseguirem classificar apenas objetos que são linearmente separáveis, isto é, existe um limite que os separa.

Perceptron Multicamadas

Para problemas não linearmente separáveis, uma alternativa é acrescentar camadas intermediárias de neurônios. Uma rede com uma camada intermediária pode implementar qualquer função contínua, pois a utilização de uma ou mais camadas permite a aproximação de qualquer função (HAYKIN, 2001; CYBENKO, 1989).

As redes perceptron multicamadas MLP (*multilayer perceptron*) possuem uma ou mais camadas intermediárias de neurônios e uma camada de saída. Utilizam nas camadas intermediárias funções de ativação não lineares, como a função sigmoidal, e cada neurônio realiza uma função específica, que é resultado da combinação das operações realizadas pelos neurônios da camada anterior que estão conectados à ele, de modo que à cada avanço, o processo torna-se mais complexo (HAYKIN, 2001; FACELLI, *et al*, 2011).

As redes neurais artificiais multicamadas podem ser treinadas por algoritmos. A escolha do algoritmo é baseada na análise das características de cada algoritmo, no intuito de, empiricamente, se chegar ao que mais se adequa ao problema em questão. A seguir, serão explanados alguns algoritmos de treinamento que podem ser usados para redes neurais artificiais.

Algoritmos de Treinamento

O desenvolvimento do algoritmo de treinamento *back-propagation*, por Rumelhart, Hinton e Williams em 1986, precedido por propostas semelhantes ocorridas nos anos 70 e 80, mostrou que é possível treinar eficientemente redes com camadas intermediárias, até então um obstáculo, resultando em um modelo de Redes Neurais Artificiais comumente conhecido atualmente, as redes *perceptron* multicamadas (MLP), treinadas com o algoritmo *back-propagation* (FACELLI *et al*, 2011; HAYKIN, 2001; RUSSELL & NORVIG, 2004).

O algoritmo *back-propagation* é baseado na regra delta utilizada pela rede adaline, também conhecido como regra delta generalizada. Assim, o treinamento consiste da iteração de duas fases, uma para frente (*forward*) e uma fase para trás (*backward*). Primeiramente na fase *forward*, um padrão é apresentado à camada de entrada da rede. Cada neurônio da primeira camada intermediária recebe o objeto, pondera o peso associado às suas conexões de entrada correspondentes, aplica a função de ativação e produz um valor de saída, que é propagado como valor de entrada pelos neurônios da camada seguinte. O processo flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída, que é então comparado ao resultado desejado. A diferença entre os valores indica o erro cometido pela rede. O erro é utilizado na fase *backward*, onde é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado (FACELLI *et al*, 2011; HAYKIN, 2001; RUSSELL & NORVIG, 2004).

O uso do algoritmo *back-propagation* implica na determinação de um ganho ou taxa de aprendizado para o treinamento da rede. Esta taxa é uma constante de proporcionalidade no intervalo $[0,1]$. O valor desta taxa tem influência direta no tempo que a rede leva para convergir. Com a taxa muito pequena, pode ocorrer a necessidade de muitos ciclos para a indução de um bom modelo. Por outro lado, uma taxa elevada pode provocar oscilações que dificultam a convergência. Quanto maior for esta constante, maior será a mudança nos pesos, aumentando a velocidade de aprendizado, entretanto, podendo levar a tais oscilações. Uma possível solução é introduzir o termo *momentum*, que quantifica o grau de importância da variação de peso do ciclo anterior ao ciclo atual. É exatamente isso que faz o algoritmo *back-propagation* com termo *momentum* (RUMELHART & MCCLELLAND, 1986). Neste algoritmo, o cálculo para o ajuste dos pesos torna o aprendizado mais estável e acelera a convergência (RUSSELL & NORVIG, 2004).

Os ciclos de treinamento do *back-propagation* são iterados até chegar ao critério de parada. A escolha deste critério possui grande variação, podendo ser por exemplo, um número máximo de ciclos ou uma taxa mínima de erro.

Um fenômeno que pode ocorrer é o chamado *overfitting*, que é quando a rede para de aprender ou se torna superajustada aos dados de treinamento, isto é, ela memoriza os dados. Isto é perceptível quando o erro de validação dos dados começa a subir. Uma maneira de reduzir a ocorrência de *overfitting* é usualmente separar uma parte dos dados do conjunto de treinamento para serem comparados a cada ciclo, isto é, é feita uma validação cruzada.

A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados. O objetivo é estimar o quão preciso é este modelo com um novo conjunto de dados. Existem técnicas de fazer a validação, mas o conceito central delas é o particionamento do conjunto de dados em subconjuntos mutualmente exclusivos, e posteriormente, a utilização de alguns destes subconjuntos para a estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos (dados de validação ou de teste) são empregados na validação do modelo (KOHAVI, 1995).

Por padrão, o *back-propagation* ajusta os valores de uma RNA para cada objeto individualmente. Há uma variação chamada modo *batch* que ajusta os valores uma única vez por ciclo. Há também outras variações conhecidas e utilizadas do algoritmo como *quick-propagation*, *Levenberg-Marquardt*, *momentum* de segunda ordem, *Newton* e *resilient-propagation* (RUSSEL & NORVIG, 2004).

Há variações que visam acelerar o *back-propagation*, aumentando a velocidade de convergência do treinamento, visto por autores como um dos problemas do algoritmo. Um exemplo é o algoritmo *resilient-propagation*, onde o ajuste do parâmetro de velocidade de aprendizado é feito durante o aprendizado, uma vez a cada época de treinamento, sendo que o valor da atualização dos pesos é calculado pela avaliação do sinal do gradiente local de cada peso, e não de seu valor (FREITAS *et al*, 2002). Há também o *quick-propagation*, que usa um modelo quadrático simples da superfície da falha (calculada independentemente de cada peso), usando o conhecimento sobre a derivada de ordem superior para acelerar a convergência (FAHLMAN, 1988).

Projeto da Arquitetura de uma RNA

A configuração referente a quantidade de neurônios das camadas ocultas de uma RNA depende de vários fatores, como o tamanho do conjunto de treinamento, a quantidade de ruído (valores que não devem ser considerados) no conjunto, a complexidade da função a ser aprendida e a organização estatística dos dados do conjunto (FAHLMAN, 1988; HAYKIN, 2001).

A definição da arquitetura da RNA é o ponto inicial que se deve dar atenção, pois envolve as funções de ativação e topologia da rede, para que posteriormente esta possa induzir um modelo para o conjunto de treinamento. A topologia da rede engloba número de camadas, quantidade de neurônios, padrão de conexões e existência ou não de retropropagação (FAHLMAN, 1988; HAYKIN, 2001)

Esta definição não é uma tarefa trivial. Normalmente o que ocorre é um processo de tentativa e erro, já que não existe nem faz sentido um padrão de configuração para uma RNA. Assim, são testadas e avaliadas várias arquiteturas para posteriormente uma ser escolhida, considerando a acurácia preditiva (FAHLMAN, 1988; HAYKIN, 2001).

Segundo Beale & Jackson (1990), para aumentar a velocidade de convergência de uma rede neural, também pode-se manipular seus pesos e parâmetros de aprendizado. O parâmetro taxa de aprendizado (*learning rate*) tem grande influência durante o treinamento. Uma taxa muito baixa torna o aprendizado da rede muito lento, enquanto uma taxa muito alta, gera oscilações e impede a convergência do processo de aprendizado. Seu valor varia de 0 a 1. O parâmetro *momentum*, tendo seu valor variando também varia de 0 a 1, consiste em adicionar, quando do cálculo do valor da mudança do peso sináptico, uma fração proporcional à alteração anterior. Assim, a introdução desse termo na equação de adaptação dos pesos tende a aumentar a estabilidade do processo de aprendizado, favorecendo mudanças na mesma direção.

Para se trabalhar com redes neurais, realizando suas configurações, alterações de parâmetros e testes com algoritmos e métodos, existem os chamados simuladores e redes neurais. Eles podem ter ou não uma interface visual, e dão suporte para o treinamento de RNA's. Existem também *frameworks* para linguagens de programação, que também permitem a manipulação da rede, e podem ser incorporadas diretamente no código do sistema desenvolvido. Pode-se citar os já conhecidos JavaNNS (JAVANNS, 2015), o Neuroph (NEUROPH, 2015), o WEKA (WEKA, 2015) o *Encog* (ENCOG, 2015), e o *BrNeural* (BRNEURAL, 2011), que será abordado oportunamente nos próximos tópicos.

Exposto isto, optou-se por trabalhar com as técnicas de processamento digital de imagens juntamente com a técnica de aprendizado de máquina redes neurais artificiais para não sobrecarregar o *smartphone* com uma sequência de tarefas de PDI, pela familiarização com as técnicas e pelo encontrado no levantamento bibliográfico, que mostra que RNA's apresentam bons resultados trabalhando com imagens.

2.4 Aplicações Móveis

Um aplicativo móvel, também conhecido como *app*, é um software que é instalado diretamente em algum dispositivo eletrônico portátil, como por exemplo, em *smartphones*, *tablets* ou *palmtops*. Os aparelhos possuem um sistema operacional (SO) para o seu funcionamento, assim, através de lojas virtuais específicas de cada SO, tais aplicativos podem ser baixados nos dispositivos, de modo que assim é garantida a compatibilidade com seus sistemas operacionais.

As lojas virtuais, como por exemplo, a *GooglePlay* (GOOGLE PLAY, 2015) para o SO *Android* (ANDROID, 2015), *Apple Store* (APPLE STORE, 2015) para o SO *iOS* (IOS, 2015) e a *Windows Phone Store* (WINDOWS PHONE STORE, 2015) para SO para *Windows Phone* (WINDOWS PHONE, 2015), permitem realizar *downloads* de aplicativos móveis de várias categorias, como jogos, aplicativos relacionados à saúde, educação, cultura, transporte, turismo, entre muitos outros, de forma gratuita ou paga.

Todo aplicativo possui uma finalidade distinta, e de modo geral, o principal objetivo é auxiliar e facilitar o dia-a-dia do utilizador.

Entre setembro de 2013 e setembro de 2014 o volume total de downloads de aplicativos móveis no Brasil (somando *Google Play* e a *App Store*) dobrou, segundo indica um relatório da consultoria *App Annie* e da associação de empresas de comércio móvel MEF (APP ANNIE, 2014). O país é hoje o segundo maior mercado em quantidade de downloads de aplicativos na *Google Play*, perdendo apenas para os EUA. No mesmo período, a receita com *downloads* e vendas *in-app* em *Android* e *iOS* aumentou 40% no Brasil.

O relatório destaca a crescente popularidade da *Google Play* nos mercados emergentes pelo sucesso de aparelhos com SO *Android*, que são mais baratos, nos mesmos. O relatório afirma que a loja da *Google* tem taxas de *downloads* 60% maiores que as da loja da *Apple*. Esta diferença percentual era de 25% em 2013.

Segundo a UIT – União Internacional das Telecomunicações, agência da Organização das Nações Unidas (ONU, 2013), há hoje no mundo seis bilhões de celulares, e a

previsão para o fim de 2014, era de que o número de celulares se igualasse ao número de habitantes, isto é, 7 bilhões.

Neste cenário, com o crescente aumento em número de celulares, é possível observar uma tendência de aumento constante na utilização de aplicativos móveis.

2.4.1 Benefícios dos Aplicativos Móveis na Agricultura

Com uma breve busca nas lojas de aplicativos, é possível encontrar aplicativos, por exemplo, que trazem acervos sobre características de doenças e pragas para auxiliar na identificação das mesmas (FMC Agrícola Brasil (FMC, 2015)), aplicativos que ajudam a identificar deficiências nutricionais da lavoura (Yara CheckIt (YARA BRASIL, 2015)), aplicativos específicos de agricultura de precisão (CR Campeiro (CRCAMPEIRO, 2015)), entre muitos outros. O Ministério da Agricultura também lançou um aplicativo, o SIGLA (SIGLA, 2015), que permite ao produtor rural que recebeu equipes de fiscalização em sua propriedade rastrear o andamento da análise do produto recolhido, processo que leva em torno de 15 dias úteis para ser concluído.

Problemas na agricultura que podem ser computacionalmente modelados, de modo geral, podem ser desenvolvidas soluções em aplicativos móveis. O fato de estar em um dispositivo móvel permite a portabilidade do app, isto é, permite sua utilização em qualquer lugar.

2.4.2 A Plataforma *Android*

A plataforma *Android* é um sistema operacional de código aberto desenvolvido para dispositivos móveis, lançado pela empresa *Google* em 2007. O SO é resultado da união de um grupo chamado *Open Handset Alliance* (OHA), formado por grandes empresas do mercado de telefonia e celulares, como *HTC*, *LG*, *Motorola*, *Samsung*, *Sony Ericsson*, *Toshiba*, *Acer*, *Dell* entre muitas outras, sendo liderada pela *Google* (LECHETA, 2013). É baseado em Linux, com diversas aplicações já instaladas, interligação com GPS, e um ambiente de desenvolvimento robusto e flexível. Atualmente está presente em mais de 1 bilhão de celulares (ANDROID, 2015). Sendo de código aberto, e possuindo uma arquitetura flexível, permite que usuários com conhecimento necessário sejam capazes de criar aplicativos para a plataforma, bem como personalizar a própria e outros apps.

É possível utilizar a linguagem Java, popular entre os desenvolvedores, para o desenvolvimento de aplicações para *Android*. É possível integrar aplicações, sejam nativas ou desenvolvidas por um programador, para a plataforma, não há distinção entre um e outro. A plataforma dispõe de recursos para a criação dos mais diversos tipos de aplicativos móveis, como suporte a mapas, jogos, recursos visuais, gerenciamento de memória, suporte a gráficos 3D, entre outros.

2.5 Trabalhos Correlatos

Há na literatura trabalhos realizados para auxiliar em questões agrícolas fazendo uso de recursos de inteligência artificial, como processamento de imagem, técnicas de redes neurais ou ainda a combinação das duas, na análise de imagens agrícolas direcionadas para diversas finalidades, entre elas, o reconhecimento de patologias em culturas agrícolas. A seguir, é demonstrado um levantamento de estudos relacionados da área de inteligência artificial, com o intuito de embasar quanto à motivação, métodos e técnicas do tema a ser desenvolvido neste trabalho.

Rogenski *et al* (2012) utilizaram redes neurais artificiais para estimar infecções por manchas foliares na cultura do trigo. Para os autores, informações climáticas afetam direta ou indiretamente a infecção por doenças em culturas, deste modo, realizaram a estimativa com dados agrometeorológicos em conjunto os graus de severidade das folhas infectadas para o treinamento da rede neural. No treinamento da RNA foi utilizada foi o backpropagation, com múltiplas camadas. Concluíram que a o sistema teve boa capacidade de classificação dos índices de infecção por doenças, e que as redes neurais estão preparadas para auxiliar na agricultura, necessitando de implementação de técnicas como a seleção rigorosa dos dados e a validação cruzada.

Khatchatourian & Padilha (2008), empregaram processamento de imagens digitais com redes neurais artificiais para o reconhecimento de variedades de soja, por meio da forma e do tamanho das sementes. Propuseram uma alternativa à classificação de diferentes cultivares de soja, tarefa realizada por inspeção visual, que é imprecisa, e ao uso de produtos químicos e testes de DNA, que possuem alto custo. Deste modo, realizaram a aquisição das imagens, cujo conteúdo eram as sementes das várias espécies de soja, dispostas sob uma superfície plana de material preto e fosco. Então, foram realizadas as seguintes etapas do processamento digital: pré-processamento, segmentação, representação, reconhecimento e interpretação, gerando como resultado final uma imagem binária, bem como uma matriz

correspondente a cada semente. Por fim, definiram a estrutura da rede neural, com aprendizado baseado no algoritmo *backpropagation*, e então submetida a treinamento. Concluíram que a combinação das duas técnicas foi eficiente neste caso, tendo uma estrutura de RNA complexa, e alta qualidade das imagens empregadas.

Chagas *et al* (2009) avaliaram a eficiência dos classificadores RNA's e os de máxima verossimilhança (Maxver), combinados com imagens de sensoriamento remoto, para classificar os níveis de degradação em pastagens na região da Zona da mata Mineira. Utilizaram imagens do sensor ASTER (ENGESAT, 2014) na identificação dos níveis (moderado, forte e muito forte), assim, o estudo propõe uma tentativa na classificação de uma mesma classe informacional (pastagem), em diferentes níveis de degradação. Fizeram uso do simulador de redes neurais “Java Neural Network Simulator (JAVANNS, 2015)”, utilizando o algoritmo *back-propagation*, testando diferentes estruturas de rede, estipulando um tamanho de 250 amostras para treinamento e de 150 para validação. Deste modo, alimentaram os classificadores com dados sobre as imagens do sensor, e efetuaram o treinamento e a validação dos dados pelos dois classificadores. Como resultados, as redes neurais, embora tivessem apresentado resultado superior, obtiveram desempenho estatisticamente semelhante ao obtido pela classificação pelo Maxver, com um índice Kappa de 0,80, contra 0,79, respectivamente.

Varella *et al* (2002) desenvolveram um programa classificador para estimar a porcentagem de cobertura do solo, fator importante no processo de erosão, através de RNA's e imagens digitais coloridas. A utilização das redes neurais é apresentada como alternativa à abordagem da classificação via obtenção de informação textural de imagens, que segundo os autores, necessita de um recurso computacional de hardware maior, isto é, mais núcleos de processamento, e por vezes resulta em um tempo de processamento superior ao esperado pela aplicação em questão. Deste modo, a utilização como dados de entrada da RNA os valores numéricos de um pixel e seus vizinhos, também torna-se uma alternativa para a classificação de imagens onde os objetos não podem ser diferenciados utilizando-se da técnica da limiarização. Desta forma, após a aquisição das imagens, estas foram pré-processadas e alimentaram uma estrutura de RNA baseada em retropropagação de erro com multicamadas, então foram validados o programa e o classificador. Encontraram uma estrutura ideal para o estudo, com as validações obtiveram índice de exatidão global médio na classificação de 82,10% no programa computacional e concluíram que as redes neurais podem ser utilizadas para análise de cobertura do solo, mesmo quando não há possibilidade da aplicação da técnica da limiarização.

Sena Júnior *et al* (2001) desenvolveram um algoritmo de processamento e análise de imagens digitais para identificação de plantas de milho atacadas pela lagarta do cartucho, para auxiliar na tomada de decisão quanto ao uso de defensivos. De acordo com os autores, a lagarta é uma praga que consome grande parte da área foliar antes das folhas de abrirem, considerada por especialistas a principal praga do milho. O processamento da imagem deu-se com a aquisição da mesma, após uma prévia classificação dividindo a imagem em blocos de 60x60 pixels e então a classificação como folha sadia, solo/resíduo ou suspeitos de ataque, e por fim uma classificação refinada, dividindo os blocos suspeitos em sub-blocos de 3x3 pixels e classificação em folha sadia, solo ou folha atacada. A arquitetura da rede foi multicamadas (MLP), baseada no método retropropagação de erro, com funções de transferência hiperbólica e sigmoide para camadas ocultas e de saída respectivamente. Realizaram os treinamentos e testes com várias estruturas de redes. As redes com mais camadas ocultas apresentaram melhor resultado. A exatidão de cada etapa do algoritmo foi acessada através da determinação da matriz de contingência, com base em 80 e 75 blocos, para a classificação grosseira e refinada, respectivamente. O algoritmo apresentou índice de exatidão global de 80,74%.

SUO *et al* (2010) apresentaram um método para se obter o teor de clorofila a partir de imagens de plantas de algodão, via processamento digital de imagens e redes neurais artificiais. Segundo os autores, o teor de clorofila é um índice muito importante que reflete diretamente o estado de saúde da planta, e a aquisição precoce de seus índices é muito importante para acompanhamento do crescimento e diagnóstico de doenças. Foi empregada uma rede neural multicamadas com algoritmo de aprendizado *backpropagation*. Utilizaram o sistema de cor RGB (*Red-Green-Blue*) nas imagens adquiridas, e a partir disso obtiveram o valores de HSI (*Hue-Saturation-Intensity*). Aplicaram filtros e manipularam os canais de cor, o que resultou na escolha de 19 componentes de cor de cada pixel, e então com estes dados, alimentaram a rede neural proposta, sendo 30 imagens para treinamento e 17 para teste. Os resultados utilizando o sistema proposto foram comparados e estavam de acordo com os obtidos através do método tradicional. O erro médio de previsão para a densidade relativa de clorofila nas 17 imagens de ensaio foi de 8,41 %. Concluíram que a utilização das redes neurais com processamento digital de imagens para este caso de predição de clorofila, é um método eficaz, levando em conta o fato de ser automatizado e ter seus resultados demonstrados em tempo real. Deste modo, o método pode ser estendido a outras culturas e também pode ser aplicável à predição de nitrogênio, devido à forte correlação entre este elemento e a clorofila.

Arribas *et al* (2011) construíram um sistema de classificação de imagens de folhas automático para as culturas de girassol, por meio de redes neurais, que podem ser usados em aplicações de herbicidas seletivos. O sistema é dividido em quatro etapas principais. Primeiro, as imagens são segmentadas no espaço de cor RGB. Em seguida, características diferentes são detectadas e extraídas a partir da imagem segmentada. Após isto, o conjunto de características mais discrimináveis é selecionado. Finalmente, uma rede neural generalizada (*Generalized SoftMax Perceptron*) é usada juntamente com o algoritmo de recentemente proposto *Posterior Probability Model Selection* (PPMS), a fim de selecionar as folhas em uma imagem e, em seguida, classificá-las como girassol ou não girassol. Com os experimentos, os resultados mostram que o sistema proposto consegue um elevado nível de precisão com apenas cinco características discriminativas selecionadas, e a obtenção de uma taxa de classificação correta média de 85% para o conjunto de teste.

Zhan *et al* (2010) analisaram a capacidade da combinação de redes neurais artificiais com a refletância hiperespectral da panícula (cachos) do arroz, para discriminar diferentes níveis de infecção causados por dois diferentes fungos. A refletância foi medida em laboratório, através da escala de comprimento de onda de 350 a 2500nm (nanômetros) com um espectroradiômetro portátil. Foi feita uma análise de componentes principais para obter os principais componentes da reflectância (bruto, logarítmica inversa, primeira e segunda derivada). Foi empregada a aprendizagem de quantização vetorial (LVQ) na rede neural para classificar em níveis saudável, de infecção leve, moderada e grave. A acurácia da classificação foi avaliada com precisão total e pelo coeficiente Kappa. As precisões globais de LVQ com APC de bruto, logarítmica inversa, primeira e segunda derivada foram respectivamente 91,6% , 86,4%, 95,5 % e 100 % e os coeficientes Kappa foram de 0,887 , 0,818 ,0,939 e 1.

Wheizeng *et al* (2008) utilizaram processamento digital de imagem estimar a severidade de doenças em folhas de culturas. Fotografaram folhas de soja em ambiente controlado, segmentaram as áreas de interesse utilizando técnicas de processamento de imagem, como histograma, limiarização, detector de bordas Sobel e dilatação, no intuito de separar apenas as lesões na folha. Por fim, a severidade das doenças nas folhas é então graduada pelo cálculo do quociente entre a área de lesão e a área foliar.

Patil & Bodhe (2011) fizeram um trabalho muito semelhante ao de Wheizeng *et al* (2008). Utilizaram técnicas de processamento digital de imagem para estimar a severidade de doenças causadas por fungos em cana-de-açúcar, que são doenças predominantes e aparecem como manchas nas folhas, no intuito de estabelecer a quantidade e concentração adequada de

pesticidas. Fotografaram 90 folhas de cana-de-açúcar em ambiente controlado com fundo branco. Empregaram métodos simples, o de limiarização e Triângulo de limiar, para segmentar a área foliar e a área da região da lesão, respectivamente. Finalmente doenças são categorizadas pelo cálculo do quociente entre a área de lesão e área foliar. A precisão do ensaio é foi de 98,60%.

Cui *et al* (2009) queriam detectar a ferrugem asiática e detectar seus níveis de severidade. Coletaram 48 imagens de folhas de soja com níveis de severidade não visível, suave, médio e severo, usando um espectroradiômetro e uma câmera multiespectral, sob a luz natural do dia. Os espectros de refletância de cada um dos níveis representativos, envolvendo diferentes níveis de infecção da ferrugem, foram utilizados para a análise. Coletaram também índices de vegetação, como NDVI (Índice de Vegetação por Diferença Normalizada), GNDVI (Índice de Vegetação da Diferença de Verde Normalizado), RVI (Índice de Vegetação Simples), GRVI (Índice de Vegetação de Verde Simples), DVI (Diferença de Índice de Vegetação), e NDGI (Índice de Diferença de Verde Normalizado), para testar suas capacidades em distinguir severidades da infecção. Utilizaram uma abordagem de três passos, sendo o primeiro a separação da área infectada da imagem original, identificação da cor da lesão e por fim a quantificação da severidade da ferrugem. A segmentação foi feita baseada em limiarização do valor de cinza para cada nível de severidade. Os resultados indicaram que tanto a fase de desenvolvimento da folha e a severidade da infecção da ferrugem mudaram a refletância de superfície dentro de uma ampla faixa do espectro. Em geral, as folhas velhas com infecção mais grave resultaram em menor refletância. Um índice de vegetação por diferença (DVI) mostrou uma correlação positiva com as diferenças de refletância. No entanto, não provava solidamente que essa mudança foi exclusivamente causada pela ferrugem. Como uma alternativa, extraíram então das imagens multi-espectrais três parâmetros, a relação da área infectada (RIA), o índice de cor da lesão (LCI) e o índice de severidade da ferrugem (RSI), utilizado para detectar a infecção foliar e gravidade da infecção. Os resultados preliminares obtidos a partir dos testes em laboratório demonstraram que o método da imagem multiespectral poderia quantitativamente detectar a ferrugem da soja. Quando a folha não está infectada, todos os pixels devem ter seu valor de LCI negativo mostrado em seu histograma, com pixels distribuídos para o lado esquerdo do ponto demarcado. Folhas com severamente infectadas, muitos pixels apresentam valor de LCI positivo, distribuídos do lado direito do histograma. Um histograma que apresenta a distribuição de LCI dos dois lados pode ser quantificado como uma folha com média severidade. Outros testes de escala de campo são necessários para verificar a eficácia e

viabilidade deste método de detecção para detectar e quantificar a infecção da ferrugem da soja no campo em tempo real de aferição.

Husin *et al* (2012) desenvolveram um sistema embarcado em um dispositivo móvel para o reconhecimento de folhas de ervas, utilizando técnicas de processamento digital de imagem e redes neurais artificiais. Não havia nenhum sistema comercial parecido, e a maneira atual de identificar ervas é feita manualmente, propensa a erros, então os autores desenvolveram um sistema automático de reconhecimento baseado nas características estruturais das folhas, como forma e textura. Para isto, após a aquisição das imagens totalizando duas mil amostras, foram efetuados processos como conversão para escala de cinza, limiarização, detecção de bordas, extração de características e reconhecimento. Alimentaram então uma rede neural *feedforward* adaptada, criada a partir de um novo algoritmo combinado com o código da função *newff* existente na ferramenta MatLab (MATLAB, 2015). Desenvolveram então o protótipo de um dispositivo portátil composto de uma placa microcontroladora, 128k de memória RAM, um regulador de fonte de energia, duas portas seriais, teclado, câmera, entrada para cartão de memória e uma tela colorida. Cem amostras de cada espécie (total de 20) foram usadas no sistema e a precisão do reconhecimento foi em 98,9 %, e o sistema é capaz de identificar espécies de folhas de ervas não importando se estão secas, molhadas, rasgadas ou deformadas.

Como se pode perceber, existem vários trabalhos da área de inteligência artificial voltados para auxiliar em questões agrícolas.

Cada trabalho que combina RNA's e PDI utiliza a seleção dos atributos das imagens que serão consideradas para o treinamento da rede neural de maneira específica para a área de aplicação a que estão se propondo, isto é, não há um modelo que possa ser seguido para aplicações que se utilizam das mesmas técnicas para finalidades semelhantes, pois para cada caso é necessária uma análise diferente. Quanto à metodologia de trabalho das redes neurais, esta consiste na tentativa e erro das calibrações de seus parâmetros e alteração de suas estruturas. Existem, de fato, recomendações na literatura para tentar se chegar à melhor configuração, todavia, ocorre o mesmo com a seleção dos atributos descritores de imagens citado anteriormente, isto varia para cada caso de aplicação.

Na área de PDI aplicada à detecção de doenças em imagens de folhas, foram encontrados trabalhos que se utilizam de métodos muito semelhantes, baseados na segmentação da folha, utilizando histogramas analisando as lesões das doenças, como

Assim, ao se realizar o levantamento literário, constatou-se que trabalhos que combinam as duas tecnologias especificamente para a identificação de patologias foliares

ainda não são comumente encontrados, apesar de serem verificados estudos que façam esta agregação para outras finalidades nas questões agrícolas.

3. MATERIAIS E MÉTODOS

Este capítulo aborda os procedimentos adotados para o desenvolvimento do trabalho de pesquisa. Envolve a preparação, a explanação do estudo de caso que embasou a continuidade da pesquisa, posteriormente o processo de aquisição de imagens, o processamento digital das mesmas, a etapa relacionada à rede neural e as características do aplicativo resultante da pesquisa bem como imagens ilustrativas do mesmo.

3.1 Estudo de Caso

Antes de se iniciarem os estudos e testes para o diagnóstico automático da severidade da ferrugem asiática da soja, foi desenvolvido um estudo de caso prévio para se testar a viabilidade da pesquisa. O estudo de caso teve condições semelhantes ao do estudo principal.

No período em que se iniciaram os procedimentos da realização do estudo de caso, havia na Fazenda Escola da Universidade Estadual de Ponta Grossa (UEPG), uma estufa com soja plantada fora de época. As plantas estavam infectadas com o oídio. A estufa fazia parte de um projeto de estudo dos alunos do curso de agronomia, coordenado pelo professor David Jaccoud, responsável pelo grupo de Fitopatologia Aplicada do curso de Agronomia.

O oídio é uma das doenças da soja, que desde 1997 vem sendo incidente em diversos cultivares. Ela se espalha pelo vento e é caracterizada por um fungo que produz uma teia na superfície da planta, e pode impedir a fotossíntese fazendo com que as plantas sequem e caiam prematuramente (SARTORATO & YORINORI, 2001), assim, faz-se importante o reconhecimento da doença em seus primeiros estágios, a fim de evitar maiores danos.

Para realizar os testes, foram coletadas aleatoriamente 157 amostras de folhas de soja da estufa, sendo reservadas 38 para testes. Como a escolha foi aleatória, parte delas estava sadia e parte infectada com a doença oídio, sendo que ao final, havia amostras englobando todos os níveis de severidade. Esta garantia de estar coletando amostras de todos os níveis foi assegurada devido ao auxílio de um dos alunos do professor coordenador, conhecedor da doença, que estava presente na coleta.

O local da coleta, a Fazenda Escola da UEPG, está a aproximadamente três quilômetros do Campus Uvaranas, na cidade de Ponta Grossa. A Figura 16 mostra a estufa em que foi realizada a coleta, no dia 10 de julho de 2013.

Figura 16 - Coleta das folhas de soja realizada na estufa no dia 10/07/2013




Fonte: A autora.

A escala de severidade adotada é dividida em vários níveis, correspondentes à escala diagramática sugerida por Mattiazzi (2003), como mostra a Figura 17.

Além dos oito níveis da escala, foi adicionado o nível 0 correspondente à 0% de severidade, ou seja, uma folha sadia, e ainda um décimo nível, na lacuna entre 43,65% e 60%, para facilitar o diagnóstico automatizado. Assim, a totalidade dos níveis foi nomeada como sendo de 0 a 9.

Figura 17 - Escala diagramática para severidade do oídio da soja



Fonte: MATTIAZZI (2003).

Após a coleta, houve o processo de aquisição das imagens. As folhas foram fotografadas com uma câmera de celular de 5.0 megapixels (5 milhões de pixels), com resolução 2592x1944 (horizontal x vertical) sobre uma superfície branca, com duas lâmpadas fluorescentes incidentes sobre a folha. Posteriormente, foram salvas no computador em seu formato de imagem original de captura .jpg¹.

A partir daí iniciou-se então a etapa de pré-processamento das imagens. Foi desenvolvida uma aplicação para *smartphone* com a tecnologia *Android*, para ser instalada e utilizada no mesmo. A aplicação realizava o pré-processamento da imagem e sua extração de características.

Assim, os arquivos jpg primeiramente tiveram sua resolução reduzida para 640x480, tamanho que após testes, mostrou melhor resultado para na manipulação das imagens. Após isto, foram submetidos a vários filtros e operações, em torno de 15, para se chegar a uma figura cuja extração de características não fosse prejudicada pelas áreas que não representavam a folha da soja na imagem. Deste modo, também após testes, chegou-se à

¹ .JPEG(.JPG): <http://www2.ic.uff.br/~aconci/curso/formatos.htm>

seguinte combinação de processos, em ordem: filtro da mediana e filtro gaussiano para suavização e retirada de ruídos, conversão para escala de cinza, detector de bordas Canny, dilatação aplicada duas vezes consecutivas, encontra e desenha contornos (correspondentes a *MedianBlur*, *GaussianBlur*, *bgr2gray*, *Canny*, *dilate*, *find* e *drawcontours* na biblioteca *OpenCv*, respectivamente), e por fim, recorte para eliminar o fundo.

Posteriormente, foram extraídas as características relevantes da imagem. O princípio utilizado foi os descritores de Haralick (HARALICK *et al*, 1973). Desta maneira, foram extraídas as médias nos canais de cores RGB e variância, e para estabelecer um comparativo para o estudo de caso, também foram extraídos os atributos máxima probabilidade, entropia, homogeneidade, contraste, e correlação da matriz de coocorrência, a fim de apurar qual descreveria melhor a textura das imagens da folha da soja na classificação.




Por fim, após a extração de tais características, foram gerados dois arquivos no formato .arff, aceito como entrada na ferramenta para mineração de dados Weka (WEKA, 2015). Weka é uma ferramenta com vários algoritmos de aprendizado de máquina, que foi escolhida para o estudo de caso e utilizada para treinamento da rede neural e identificação dos graus de severidade.

Os arquivos continham todas as características extraídas de cada uma das 119 folhas; um dos arquivos continha as médias RGB e a variância, e o outro continha as médias RGB e os valores da matriz de coocorrência. Assim, estas características foram submetidas à rede neural, cujo tipo de aprendizado escolhido foi o de aprendizado supervisionado, e algoritmo baseado em *backpropagation*.

Deste modo, a aplicação desenvolvida fazia o gerenciamento de todo o processamento da imagem. Primariamente, possuía interface simples. Ao iniciar o programa, a câmera era acionada, aguardando que o usuário pressionasse a opção “Capturar Imagem”. Após a captura, o aplicativo processava a imagem primeiramente, submetendo-a a todas as operações e filtros, e após isto, extraía suas características. O resultado era um arquivo .arff com as características respectivas de cada folha que foi fotografada, e sua respectiva severidade. Após, foram sendo feitas melhorias na interface do aplicativo, objetivando a melhoria na manipulação do mesmo, entretanto as funções permaneceram as mesmas.

Como resultados dos processos em que as imagens do estudo de caso foram submetidas através da aplicação de procedimentos com *OpenCv* na plataforma *Android*, no Quadro 2 a seguir, apresenta-se passo a passo as transformações em sequência:

Quadro 2 - Etapas dos Filtros de Processamento de Imagem

1. Imagem Original – Folha de Soja com Oídio	2. Filtro MedianBlur
	
3. Filtro GaussianBlur	4. Conversão para escala de cinza
	
5. Detector de bordas Canny	6. Dilatação (aplicada duas vezes)
	
7. Find e DrawContours	8. Folha Recortada – Versão Final
	


Fonte: A autora.

Após a sequência de processos, obteve-se uma imagem em que não há ruídos ou irregularidades, e o fundo não interfere em sua análise, podendo este ser descartado na execução de novos procedimentos de análise.

Em seguida, após extração das características definidas, através de cálculos estatísticos disponíveis na literatura e adaptados para a aplicação, foram gerados os arquivos .arff que foram alimentação para a rede neural com a ferramenta Weka, à qual as imagens seriam sujeitadas.

Após tentativas de configurações de uma RNA adequada, chegou-se à que está representada pela Figura 18, com uma camada oculta contendo 15 neurônios. Nesta figura a representação é das características médias RGB e variância.

Figura 18 - Estrutura da RNA utilizada



Fonte: A autora.

Deste modo, com a mesma estrutura de rede, obteve-se uma acurácia de 90,75% para descrição com médias RGB e matriz de coocorrência e de 68,90% para descrição com médias RGB e variância.

Diante do exposto, verificou-se primeiramente a viabilidade do estudo do projeto de dissertação para a ferrugem asiática da soja, visto que as tecnologias empregadas apresentaram bons resultados para a aplicação. Baseado na acurácia da rede, concluiu-se que a matriz de coocorrência é um melhor descritor de textura, provavelmente porque possui mais variáveis referentes às características da imagem.

3.2 Aquisição das Imagens

O processo de aquisição de imagens de folhas de soja infectadas com a doença ferrugem asiática iniciou-se com as coletas.

As coletas foram realizadas na Fazenda Escola da UEPG, exceto a última. Esta última coleta foi necessária devido ao fato de ainda não haver folhas suficientes para determinados níveis de severidade, entretanto, a soja da Fazenda Escola já havia sido colhida. Deste modo, a última coleta foi realizada em uma fazenda na área rural da cidade de Ventania, onde alunos do grupo de Fitopatologia Aplicada também realizavam pesquisas, e onde também havia um plantio de soja tardia.

Ao todo, foram 6 coletas de folhas, nas respectivas datas: 07/03, 11/03, 18/03, 26/03, 01/04 e 13/05. Na medida em que a doença avançava, era feito o monitoramento e então a coleta das folhas, até que houvesse um número considerado suficiente de amostras.

A retirada das folhas foi concentrada nos terços inferiores e médios das plantas, devido ao fato de a doença se iniciar nas partes mais baixas da planta.

A Figura 19 é uma fotografia tirada na segunda coleta, onde acadêmicos de agronomia analisam as folhas para verificar a existência da ferrugem. A Figura 20 é uma fotografia da terceira coleta, e mostra além da autora da pesquisa, outras acadêmicas auxiliando na coleta das folhas.

Figura 19 - Segunda coleta de folhas



Fonte: A autora.

Figura 20 - Terceira coleta de folhas



Fonte: A autora.

Nas coletas em campo, as folhas eram armazenadas em sacos plásticos transparentes. Logo em seguida, eram levadas para o laboratório de fitopatologia, onde os acadêmicos faziam a triagem das folhas. Esta triagem verificava a condição da folha, isto é, se poderia ser

aproveitada para o estudo ou se estava demasiadamente danificada que devesse ser descartada. As que poderiam ser aproveitadas passavam então a ser separadas pelos níveis de severidade. Os níveis estabelecidos foram os seguintes: Sadias, de 0,1% a 0,5%, 1%, 2%, 3%, de 3,1 a 4%, 5 a 10%, 10,1 a 15%, 15,1 a 20%, 20,1 a 30%, 30,1 a 40% e 40,1 a 50%, totalizando 12 níveis incluindo as folhas sadias. A análise dos níveis era feita observando as folhas contra a luz do céu, com utilização da lupa de aumento quando necessário.

Após a separação dos níveis, as folhas eram armazenadas nos mesmos sacos plásticos. Os plásticos eram devidamente identificados, e um papel úmido era inserido dentro dos mesmos com as folhas, em seguida era fechado com ar, e então armazenado em geladeira. Este processo chama-se incubação, e era feito para manter as folhas vivas até passarem pelo próximo passo, serem fotografadas com o *smartphone*. As coletas de folhas sempre resultavam em centenas de folhas aproveitáveis. Esta medida de incubação era então necessária, pois a coleta e a separação eram feitas no mesmo, entretanto, as fotos se estendiam do mesmo dia até o seguinte, devido à enorme quantidade de folhas a serem fotografadas, o que tornava inviável efetuar a tiragem de fotos no mesmo dia. Ao todo, foram coletadas aproximadamente 3 mil folhas de soja, destas, aproximadamente 2 mil puderam ser aproveitadas. A Figura 21 mostra um dos sacos utilizados para incubação das folhas.

Figura 21 - Folhas de soja incubadas em saco plástico




Fonte: A autora.

As folhas eram então retiradas dos sacos plásticos apenas no momento das fotos. Quando necessário, eram deixadas espalhadas para que secassem o excesso de umidade, de modo que esta não interferisse no resultado da fotografia.

O *smartphone* utilizado para a geração da base de dados (tiragem de fotos) e também para o processamento de imagens foi da marca Sony modelo Xperia ZQ, com câmera de 13 megapixels e processador com 4 núcleos de processamento de 1.5 Ghz.

O procedimento para a tiragem de fotos foi baseado em ambiente controlado. Primeiramente foi feita uma cúpula em madeira, posteriormente suas dimensões foram aperfeiçoadas e então uma cúpula em acrílico foi utilizada. A cúpula em acrílico foi desenvolvida pensando em seu possível futuro acoplamento ao robô que há no departamento de informática de UEPG (desenvolvido na dissertação de mestrado do acadêmico Daurimar Mendes), que assim teria a possibilidade de fazer a varredura na plantação de soja para o reconhecimento automatizado da ferrugem asiática da soja. A cúpula em acrílico teve ainda suas dimensões alteradas para que o *flash* tenha abertura correta ao fotografar. A Figura 22 mostra a primeira cúpula utilizada em madeira, com dimensões 10x10x9,5cm (Comprimento x Largura x Altura) e pintada de preto com tinta à base de água por dentro, e a Figura 23 mostra a cúpula aperfeiçoada, com dimensões 12x12x14cm com adesivo fosco colado por dentro, para evitar reflexos nas fotos. Ambas tem abertura na face superior para a câmera e o *flash*, projetados para o modelo de celular utilizado.

Figura 22 - Cúpula em madeira



Fonte: A autora.

Figura 23 - Cúpula em acrílico



Fonte: A autora.

As folhas foram fotografadas frente e verso, considerando que a ferrugem asiática tem características somente no verso da folha. Ao total, foram 2046 fotos de frente aproveitadas e 2019 fotos do verso aproveitadas. A distribuição entre os níveis de severidade ficou, como mostra a Tabela 2, da seguinte forma:

Tabela 2 - Distribuição dos Níveis de Severidade

Grau de Severidade	Nº Folhas Frente	Nº Folhas Verso
Sadias	160	154
0,1% a 0,5%	81	75
1%	193	193
2%	81	78
3%	155	154
3,1 a 4%	123	124
5 a 10%	344	331
10,1 a 15%	207	206
15,1 a 20%	199	200
20,1 a 30%	105	108
30,1 a 40%	274	272
40,1 a 50%	124	124

Fonte: A autora.

A Figura 24 mostra uma folha coletada, analisada pelos especialistas como sendo sadia.

Figura 24 - Folha de soja sadia



Fonte: A autora.

Já na Figura 25, podemos observar uma folha de soja analisada como tendo 3% de severidade da ferrugem asiática.

Figura 25 - Folha com 3% de severidade



Fonte: A autora.

Uma folha com 10,1 a 15% de severidade pode ser observada na Figura 26 a seguir.

Figura 26 - Folha de soja com 10,1 a 15% de severidade



Fonte: A autora.

Na Figura 27, tem-se uma folha com 20,1 a 30% de severidade da ferrugem asiática.

Figura 27 - Folha de soja com 20,1 a 30% de severidade



Fonte: A autora.

A Figura 28 exibe uma folha de soja com 30,1 a 40% de índice de severidade.

Figura 28 - Folha de soja com 30,1 a 40% de severidade



Fonte: A autora.

Na Figura 28, observa-se uma folha já com 40,1 a 50% de severidade da ferrugem.

Figura 29 - Folha de soja com 40,1 a 50% de severidade



Fonte: A autora.

Todas as fotos foram armazenadas em seu formato original de captura, .jpg com 2204 x 3920 pixels (Largura x Altura) de resolução.

3.3 O Processamento Digital das Imagens





Após todas as fotos serem fotografadas e armazenadas, iniciou-se então a etapa de pré-processamento das imagens. Neste estudo, o objetivo desta etapa foi remover ruídos das imagens e eliminar o fundo, no intuito de melhorar a extração de características, realizada posteriormente a este processo. A filtragem não é obrigatória, mas dependendo do escopo do problema e aplicação, pode fazer significativa diferença positiva.

Deste modo, foram realizados vários testes, com combinações de filtros de realce, suavização, operações para detecção de borda e operações morfológicas, a fim de verificar que combinação traria um melhor resultado final.

Após inúmeros testes, os filtros escolhidos acabaram sendo semelhantes aos utilizados no caso de teste, devido aos seus bons resultados com as folhas, com algumas pequenas alterações de regulação interna de parâmetros, como tamanho da máscara utilizada. São eles: filtro da mediana, filtro Gaussiano com máscara maior, transformação para escala de cinza, detector de bordas *Canny*, dilatação, *find* e *drawcontours*, e por fim o recorte da folha, já em RGB novamente.

A seguir, o Quadro 3 mostra as imagens resultantes após cada etapa de pré-processamento, isto é, após cada aplicação de cada filtro ou operação em uma folha exemplo infectada grau de severidade entre 15,1 a 20% de ferrugem asiática.

Quadro 3 - Etapas do pré-processamento das folhas

1. Imagem Original – Folha de Soja com Ferrugem Asiática	2. Filtro da Mediana
	
3. Filtro Gaussiano	4. Conversão para escala de cinza
	
5. Detector de bordas Canny	6. Dilatação (aplicada duas vezes)
	
7. Find e DrawContours	8. Folha Recortada – Versão Final
	

Fonte: A autora.

Na primeira figura do quadro, pode-se observar duas faixas mais escuras na imagem, uma em cima e outra em baixo. Estas faixas existem em todas as fotos, e são provenientes do método de captura, e correspondem às bordas da cúpula utilizada. Foi necessário valer-se de

técnicas de processamento para eliminar esta parte, de modo a não interferir no resultado da análise.

Ao se comparar o detector de bordas *Canny* do caso de teste com o atual utilizado para o trabalho, pode-se observar uma diferença com relação aos traços das bordas que são detectadas. Isto é explicado em primeiro lugar, pois no caso de teste, a face frontal da folha foi utilizada, e para o trabalho final, a parte posterior passa a ser importante. Em segundo lugar, os parâmetros dos filtros que causam o embaçamento acentuaram este efeito no trabalho final, no intuito de “borrar” problemas nas folhas provenientes da ação do tempo e de insetos, não alterando a “visualização” da ferrugem asiática, isto é, foram alterados parâmetros para se adaptarem melhor à situação do trabalho final. E é muito importante lembrar que a extração das características relevantes é feita em cima da última imagem, a do recorte final, com suas cores e formas preservadas, e sem ruídos ou fundo.

Posteriormente ao processo de filtragem, deu-se a etapa de extração de características. Nesta pesquisa, foram utilizadas para a realização do trabalho características de domínio geral, mais especificamente de cor e textura, considerando que a ferrugem asiática pode ser identificada visualmente. O presente estudo emprega a abordagem estatística no que diz respeito à textura.

Foram testados além dos atributos do caso de teste, outros atributos que descrevem a textura. Nestes testes de extrações de características, ajustes quanto ao tamanho da imagem necessitaram ser feitos, devido ao tempo de processamento que a extração demandava. Nos primeiros testes, para realizar a extração de apenas um grupo de folhas de um nível de severidade, o programa chegava a ficar rodando três dias. Vale contar que foram utilizados dois notebooks intercalando o processamento, um da marca Lenovo, com 4 núcleos de processamento e memória de 8 *gigabytes*, e outro da marca HP, com 2 núcleos de processamento e 4 *gigabytes* de memória.

Foram incluídos alguns outros atributos de textura para extração, entretanto, tornaram o processamento demasiadamente lento, demorando cerca de 2 horas a mais para extrair cada atributo adicionado, considerando o tamanho original da imagem. Deste modo, optou-se por gradualmente ir diminuindo proporcionalmente as dimensões das figuras, a fim de otimizar o tempo. Ainda assim, a fim de não tornar o arquivo com as características demasiadamente grande e o processamento de mesmo modo demorado, optou-se por continuar trabalhando com os canais RGB para cor, e os principais descritores de textura de Haralick, que Baraldi e Parmiggiani (1995), apontaram como sendo as mais relevantes. Assim, tem-se as médias R, G e B, as variâncias também para cada canal de cor, o segundo

momento angular, a entropia, o contraste, a correlação e a homogeneidade, e a dimensão 8 vezes menor que a original.

As combinações de filtros e os atributos para extração de características foram realizadas com o auxílio da biblioteca *OpenCV*, na linguagem Java.

A Figura 30 mostra um trecho do arquivo .csv gerado após a extração das características escolhidas das folhas de soja. Na figura aparecem linhas com valores dos atributos apenas de folhas de grau de severidade zero, isto é, folhas saudáveis. A primeira linha corresponde ao cabeçalho, isto é, são os nomes de cada coluna, sendo estes, Média RGB 2, Média RGB 1, Média RGB 0, Variância 2, Variância 1, Variância 0, Segundo Momento Angular, Entropia, Contraste, Homogeneidade, Correlação e por fim, o Grau de Severidade, de acordo com os especialistas que avaliaram as folhas.

Figura 30 - Trecho arquivo de características .csv

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	rg2,rg1,rg0,va2,va1,va0,mom,ent,con,hom,correlacao,gs												
2	61,68,46,5768,7303,3288,0.3555451798202959,3667931.834865926,128.43773744604664,0.6839544950809534,0.9933105948441259,0												
3	49,54,38,5689,6995,3496,0.477687064421905,3690369.228579552,130.4959414630013,0.7589316413536827,0.9920394598130466,0												
4	44,48,34,5551,6604,3465,0.5365177625731997,3729679.9136630506,117.56850713036222,0.7953199503632007,0.9921082028507557,0												
5	67,75,51,6180,7574,3563,0.3143378885370562,3620575.8608104666,150.07653418180274,0.6485395434055629,0.9929759383254821,0												
6	68,76,54,6124,7490,3879,0.3028945550676378,3575607.263745224,204.86818657173362,0.6239282408474023,0.9906905184430669,0												
7	69,76,55,6246,7570,3972,0.3000358023186021,3525500.72852859,187.42623532317273,0.6163625607199408,0.9916356983550856,0												
8	78,87,61,5992,7378,3619,0.22732880599664426,3550178.518242498,181.08787594625718,0.5668211148251241,0.992609597999929,0												
9	42,47,33,5325,6450,3235,0.5437108504065317,3719697.298213311,133.76243339092176,0.7900337191698669,0.9906227132146672,0												
10	5,5,4,734,831,488,0.9187487239923514,3783017.302433659,258.90666357152605,0.9620382878707231,0.8252856763194892,0												
11	36,39,29,4825,5831,3134,0.6086770725432994,3746493.218205908,110.46523342993889,0.8262314190884198,0.9910828384546507,0												
12	49,54,39,5742,6968,3649,0.47996040877934404,3699091.762649663,130.87965165624746,0.7646952042236459,0.9920673691391416,0												

Fonte: A autora.

3.4 Configuração e Treinamento da Rede Neural

Após o processo de filtragem e extração de características serem concluídos, deu-se início à etapa de configuração e treinamento da rede neural com os dados extraídos.


Esta etapa, no caso de teste, foi realizada com o auxílio da ferramenta de aprendizado de máquina WEKA. No projeto de pesquisa final, optou-se por utilizar um simulador de RNA baseado no *framework Encog*.

O *Encog* é uma ferramenta de aprendizado de máquina desenvolvido para as linguagens Java e .Net. Inicialmente, o *Encog* foi criado para suportar apenas redes neurais, posteriormente, foram incorporados outros métodos de aprendizado de máquina. Atualmente, ele suporta uma variedade de algoritmos de AM, como Máquinas de Vetor de Suporte, Redes Neurais, Programação Genética, Redes Bayesianas e outros, podendo normalizar e processar

dados. Há também uma interface para usuário, chamada *Encog Workbench* (Figura 27) que ajuda na manipulação da modelagem e treinamento de dados.

O BrNeural (BRNEURAL, 2011) é um simulador de redes neurais desenvolvido por um grupo de acadêmicos da Universidade Estadual de Ponta Grossa, coordenados pelo professor doutor Ivo Mario Mathias. Inicialmente uma versão para internet foi criada, e posteriormente uma versão desktop. Há uma versão com interface para o usuário (Figuras 31, 32 e 33), que futuramente será disponibilizada para o público, entretanto, ainda está em fase de finalização. Para o presente estudo não foi utilizada a interface.

Figura 31 - *Encog Workbench*.




Fonte: BRNEURAL, 2011.

Figura 32 - Tela Principal BrNeural



Fonte: BRNEURAL, 2011.

Figura 33 - Tela de Relatório



Fonte: BRNEURAL, 2011.

O aspecto determinante para a escolha de uma ferramenta baseada no *framework Encog* para trabalhar com a RNA, foi a possibilidade da utilização da configuração da RNA escolhida no *smartphone*. Em outras palavras, na busca pela ferramenta, observou-se para que esta permitisse, após o treinamento da RNA, a implementação da mesma, em Java na plataforma do *smartphone* para a predição com novos dados coletados a campo. Esta característica fundamental foi encontrada no *Encog*.

Após a escolha da utilização do simulador BrNeural, deu-se início à fase da instalação do mesmo no computador do projeto. O simulador sofreu algumas alterações para atender ao projeto de pesquisa em questão, como a seleção aleatória dos dados para teste.

Após as configurações de instalação do simulador terem sido realizadas corretamente no computador, e o ajuste do mesmo ao projeto estar finalizado, deu-se início à fase do treinamento.

Toda a fase de treinamento, com o ajustamento de parâmetros deu-se de forma totalmente empírica, por tentativa e erro.

Atualmente, o BrNeural trabalha com os algoritmos *back-propagation*, *resilient-propagation* e *quick-propagation*. É possível alterar os parâmetros de treinamento como número de épocas, taxa de aprendizado, *momentum*, porcentagem para teste, entre outras.

O BrNeural separa automaticamente um conjunto de dados dentro da base apresentada, bastando definir a porcentagem desejada. Por exemplo, se o desejado é separar 30% para teste, o BrNeural irá buscar aleatoriamente 30% de amostras de cada categoria existente na base de dados, de modo que esta base de dados teste fique balanceada. A aleatoriedade é definida selecionando as 30% primeiras ocorrências, no caso do exemplo, de cada classe existente.

O BrNeural ainda não possui a implementação da validação cruzada para a validação do treinamento da rede.

Inicialmente a porcentagem deixada para teste foi estabelecida em 30% do conjunto de dados, isto é, a rede neural utiliza 70% dos dados para realizar seu treinamento, e 30% para o teste posterior ao aprendizado.

Os dados de entrada e saída foram normalizados, isto é, colocados numa mesma faixa de valores. Esta normalização é necessária para evitar que uma dimensão se sobreponha em relação às outras e evitar que o aprendizado fique comprometido. Os dados de entrada foram normalizados entre os valores 0 e 1. Já os dados de saída foram normalizados pelo método *OneOf* do *Encog*. Este método garante que haja um neurônio de saída correspondente para cada resultado possível. Também foram sendo variados os testes com o método *Equilateral* também do *Encog*, que realiza o cálculos da distância euclidiana para determinar a quantidade de neurônios de saída. A técnica de normalização euclidiana utiliza menos neurônios do que a técnica *OneOf*.

A quantidade de neurônios de entrada corresponde às características das imagens, incluindo o grau de severidade, somando 12. São elas: Média RGB2, Média RGB1, Média RGB0, Variância 2, Variância 1, Variância 0, Segundo Momento Angular, Entropia, Contraste, Homogeneidade, Correlação e Grau de Severidade. A quantidade de camadas ocultas foi definida como 1. Já a quantidade de neurônios nesta camada oculta foi testada, partindo do princípio de 3 vezes a quantidade de neurônios de entrada somado à quantidade

de neurônios de saída, como sugerido por Mathias (2006). De acordo com Facelli *et al* (2011) e Russel & Norvig (2004), que para grandes quantidades de dados, muitos neurônios na camada oculta podem fazer a rede neural sofrer *overfitting*, portanto, os testes foram variando para menos.

O arquivo com as características extraídas das folhas de soja foi transformado em um arquivo de extensão .csv², formato aceito pelo BrNeural. O formato pode ser separado por vírgula ou por ponto. Vale ressaltar que o arquivo contém as características referentes às fotografias da face posterior da folha. Inicialmente o arquivo estava separado nos 12 níveis de severidade. Posteriormente foi sendo feita a junção de níveis de severidade semelhantes no intuito de tentar aumentar o aprendizado da rede. Seguiu-se o princípio que quanto menos níveis para generalizar, mais fácil é para a rede aprender. Assim, os primeiros níveis a terem suas categorias unidas foram: nível 0,1 a 0,5% unido com nível 1%, formando um só nível. Em seguida, nível 3% unido com nível 3,1 a 4%, formando um só nível. Os testes seguintes tomaram este padrão de proximidade nos níveis, isto é, uma folha com 0,5% de ferrugem asiática é semelhante visualmente a uma folha com 1% da doença.

3.5 O Aplicativo e suas características

Foi desenvolvido um aplicativo na linguagem Java para a plataforma *Android* com o objetivo de gerenciar as etapas até a efetiva predição dos níveis de severidade da ferrugem asiática da soja. O aplicativo desenvolvido trabalha basicamente da seguinte maneira: ele tira a fotografia das folhas de soja a serem analisadas, faz toda a filtragem do processamento digital da imagem, com a imagem já processada ele faz a extração das características desta imagem, em seguida estas características são mandadas para a análise da rede neural (treinada previamente via computador), e finalmente, após a análise da rede neural, ele informa o nível de severidade de ferrugem asiática naquele conjunto de folhas de soja, através de um arquivo .csv.

O programa ainda é capaz de gerar um mapa, de acordo com as coordenadas da foto, capturadas no momento da aquisição da mesma. Este mapa objetiva melhorar a visualização da área plantada e seus níveis de infecção de ferrugem, de modo que para cada nível, um ponto no mapa é pintado com uma cor distinta respectiva.

² Comma Separated Values (CSV):

http://infolib.lotus.com/resources/symphony/3.0.0/sym20abd014/pt_br/text/scalc/guide/csv_files.html

4. RESULTADOS

O Treinamento da Rede Neural

Foram realizados inúmeros testes com inúmeras combinações de parâmetros para tentar se chegar ao melhor resultado no que se diz respeito à acurácia da rede neural. A seguir, são apresentados os principais cenários de resultados de treinamento.

O primeiro cenário, com resultados apresentados na Tabela 3, teve os seguintes parâmetros:

- Níveis de severidade: 12;
- Dados para teste: 30%;
- Neurônios na Camada Oculta: 3 * neurônios de entrada + neurônios de saída;
- Neurônios da camada de saída: 1 neurônio de saída para cada nível de severidade (*OneOf*).

Tabela 3 - Melhores Resultados Primeiro Cenário

Melhores Resultados Primeiro Cenário		
Épocas	Acerto	Algoritmo
4.000	68%	<i>quick-propagation</i>
5.000	66%	<i>resilient-propagation</i>
8.000	67,22%	<i>resilient-propagation</i>
44.600	61,5%	<i>resilient-propagation</i>

Fonte: A autora.

O segundo cenário, onde tem seus melhores resultados apresentados na Tabela 4, teve uma variação apenas na quantidade de níveis de severidade, isto é, nos neurônios de entrada:

- Níveis de severidade: 8;
- Dados para teste: 30%;
- Neurônios na Camada Oculta: 3 * neurônios de entrada + neurônios de saída;
- Neurônios da Camada de Saída: 1 neurônio de saída para cada nível severidade (*OneOf*).

Tabela 4 - Melhores Resultados Segundo Cenário

Melhores Resultados Segundo Cenário		
Épocas	Acerto	Algoritmo
4.000	73,04%	<i>resilient-propagation</i>
15.000	76,21%	<i>quick-propagation</i>
15.000	76,03%	<i>resilient-propagation</i>

Fonte: A autora.

O terceiro cenário, também sofreu variação apenas nos níveis de severidade, diminuindo para 7 no total (Tabela 5). Os 7 níveis resultantes são os seguintes:

- 0,1 a 4%;
- 5 a 10%;
- 10,1 a 20%;
- 20,1 a 30%;
- 30,1 a 40%;
- 40,1 a 50%;
- Nível das Sadias.

Tabela 5 - Melhores Resultados Terceiro Cenário

Melhores Resultados Terceiro Cenário		
Épocas	Acerto	Algoritmo
4.000	76,70%	<i>resilient-propagation</i>
5.000	78.85%	<i>quick-propagation</i>
5.000	78.70%	<i>back-propagation</i>
10.000	77.70%	<i>resilient-propagation</i>
21.000	76.53%	<i>resilient-propagation</i>
24.000	76,72%	<i>resilient-propagation</i>
28.000	78.86%	<i>resilient-propagation</i>
35.000	78,34%	<i>resilient-propagation</i>
44.000	74,35%	<i>resilient-propagation</i>
44.000	75.82%	<i>quick-propagation</i>
44.600	77,31%	<i>resilient-propagation</i>

Fonte: A autora.

Já o quarto cenário, continuou com 7 níveis de severidade, mas caiu para aumentou para 50% para dados teste. Na Tabela 6 é possível ver os principais resultados do treinamento.

Tabela 6 - Melhores Resultados Quarto Cenário

Melhores Resultados Quarto Cenário		
Épocas	Acerto	Algoritmo
29.800	77.28%	<i>resilient-propagation</i>
30.000	75.42%	<i>resilient-propagation</i>
35.000	73.11%	<i>back-propagation</i>
35.000	75.29%	<i>quick-propagation</i>
35.000	74.703%	<i>resilient-propagation</i>

Fonte: A autora.

Nos seguintes cenários, quinto cenário, os 7 níveis de severidade foram mantidos, e a porcentagem para teste retornou a 30%, mas a quantidade de neurônios de saída foi alterada pelo outro método de normalização de saída do *Encog*, o *Equilateral*, e os neurônios da camada oculta também foram sendo modificados aleatoriamente para menos

Deste modo, os seguintes resultados foram selecionados como mais representativos:

- Quinto cenário: Com 40 neurônios na camada oculta e com 7 neurônios na camada de saída (Tabela 7);

Tabela 7 - Melhores Resultados Quinto Cenário

Melhores Resultados Quinto Cenário		
Épocas	Acerto	Algoritmo
17.300	69,74%	<i>back-propagation</i>
17.300	73,21%	<i>quick-propagation</i>
17.300	74,60%	<i>resilient-propagation</i>

Fonte: A autora.

- Sexto cenário: Com 28 neurônios na camada oculta e com 6 neurônios de saída (Tabela 8);

Tabela 8 - Melhores Resultados Sexto Cenário

Melhores Resultados Sexto Cenário		
Épocas	Acerto	Algoritmo
44.000	67,72%	<i>back-propagation</i>
44.000	74,37%	<i>quick-propagation</i>
44.000	75,37%	<i>resilient-propagation</i>

Fonte: A autora.

- Com 29 neurônios na camada oculta e 7 neurônios de saída (Tabela 9);

Tabela 9 - Melhores Resultados Sétimo Cenário

Melhores Resultados Sétimo Cenário		
Épocas	Acerto	Algoritmo
25.000	74,04%	<i>back-propagation</i>
25.000	78,70%	<i>quick-propagation</i>
25.000	78,20%	<i>resilient-propagation</i>

Fonte: A autora.

Empiricamente, notou-se uma falta de padrão no aprendizado no que diz respeito à utilização da ferramenta, tendo esta apresentado resultados semelhantes com treinamento sendo efetuado com baixo ou elevado número de épocas, sendo necessária cautela na análise dos resultados, de modo a não utilizar resultados camuflados com *overfitting*.

Para a utilização no aplicativo, isto é, para o aplicativo fazer o reconhecimento da severidade da ferrugem asiática da soja em folhas novas, foi escolhida a estrutura de rede do cenário 3, com 28.000 épocas de treinamento, o resultado com o algoritmo *resilient-propagation*, que apresentou acerto de 78,86%.

Foram geradas matrizes de confusão dos melhores resultados, no intuito de melhor visualizar o aprendizado da rede. A matriz de confusão da estrutura escolhida é apresentada a seguir (Tabela 10).

Tabela 10 - Matriz de Confusão da estrutura de rede escolhida

Matriz de Confusão							
0	0,1 a 4%	5 a 10%	10,1 a 20%	20,1 a 30%	30,1 a 40%	40,1 a 50%	
39	9	0	0	0	0	0	0
6	171	7	2	0	0	0	0,1 a 4%
0	5	64	30	0	0	0	5 a 10%
0	0	27	88	3	0	3	10,1 a 20%
0	0	4	21	5	0	2	20,1 a 30%
0	0	0	0	0	81	0	30,1 a 40%
0	0	0	6	2	0	28	40,1 a 50%

Fonte: A autora.

Na matriz de confusão, a diagonal representa a quantidade de acertos para a classe em questão. Por exemplo, para o nível de severidade 0,1 a 4%, nos dados de teste, a rede neural acertou 171 vezes para esta classe. Observando a linha inteira da tabela para este nível, pode-se afirmar que ela errou predizendo que as folhas neste nível eram sadias (nível 0) em 6 amostras, errou predizendo também que 7 folhas eram do nível 5 a 10%, e errou também predizendo que 2 das folhas eram do nível 10,1 a 30%.

Percebe-se que o nível em que a rede mais errou foi o de 20,1 a 30%, acertando apenas 5, e predizendo que a maioria era do nível anterior, 10,1 a 20%. Isto pode ser explicado devido à proximidade dos níveis e sua semelhança visual, bem como a quantidade pequena de amostras de folhas em relação aos demais níveis.

Deste modo, após esta escolha, a estrutura da rede neural treinada foi salva como um objeto, e inserida no aplicativo, de modo a estar pronta a receber dados novos para realizar a predição.

O Aplicativo

O aplicativo é então a ferramenta final que faz a conexão das tecnologias empregadas para que se chegue ao resultado esperado, a análise da severidade da soja.

O aplicativo é instalado como qualquer aplicativo comum para *smartphone*, e então é criado um atalho da tela do mesmo. Ao abrir o aplicativo, a tela inicial, de configuração inicial de parâmetros é apresentada (Figura 34).

Figura 34 - Tela inicial do aplicativo

Bem Vindo ao Avaliador Automático de Severidade da Ferrugem Asiática da Soja!

Pasta das imagens analisadas:

/storage/emulated/0/Soy/Fotos/2% ...

Pasta das imagens geradas

/sdcard/Soy/Fotos/10,1 a 15% ...

Pasta Arq. de características

/sdcard/Soy/Fotos/10,1 a 15% ...

Analisar a parte:

☒ Frontal

☐ Verso

☐ Salvar somente última foto

Iniciar Processar

Fonte: A autora.

No campo “Pasta das imagens analisadas” pode-se escolher o caminho onde serão salvas as fotos a serem analisadas pelo aplicativo.

O campo “Pasta das imagens geradas” nada mais é do que um campo que possibilita a escolha do local onde serão salvas as fotos das folhas a cada etapa do processo de filtragem.

O campo “Pasta Arq. de Características” refere-se ao caminho onde será salvo o arquivo com as características das folhas analisadas.


Também se pode escolher entre as opções “Frontal” e “Verso”. Ao selecionar a opção Frontal, o que se quer dizer é que a análise se dará baseada na parte frontal da folha. Caso a escolha seja “Verso”, a análise se baseará na parte posterior da folha. Esta opção foi implementada no intuito de futuramente adaptar o aplicativo para outras doenças da folha de soja. A ferrugem asiática da soja tem características acentuadas no verso de sua folha, isto é,

suas pústulas são visíveis em sua parte abaxial, por isto, a análise utilizada neste estudo foi concentrada nesta parte.

A opção “Salvar somente última foto” é importante para a otimização da capacidade de armazenamento do *smartphone*. Esta opção garante que após todas as etapas do processamento prévio antes da extração de características, apenas a última foto, após o término deste processo, seja salva, e não uma foto a cada etapa, de modo a não ocupar mais espaço do que o necessário.

Clicando no botão iniciar, será aberta a tela para tirar as fotos. Nesta tela, será aberta uma janela pedindo para habilitar o GPS (que é obrigatório), caso este já não esteja habilitado, e então ficará aguardando o comando para tirar a foto. A Figura 35 mostra o aviso, no idioma nativo do *smartphone*, quanto ao GPS desabilitado.


Figura 35 - Aviso de GPS desabilitado



Fonte: A autora.

Clicando em OK, o usuário será direcionado para a tela onde é possível ativar a opção, dentro de seu aparelho, como ilustra a Figura 36.

Figura 36 - Habilitar GPS do aparelho




Fonte: A autora.

Ao habilitar a opção, a câmera ficará habilitada pronta para fotografar.

O botão “Processar” irá realizar o processamento de todas as fotos tiradas na etapa anterior, que foram armazenadas na pasta previamente escolhida. Sendo assim o aplicativo fará o pré-processamento nas imagens, fará a extração de características e gerará um arquivo .csv com elas. Este .csv será enviado para o objeto da rede neural treinada, para que esta faça a predição dos níveis de severidade. Após esta predição, o objeto da rede neural irá gerar como resultado um outro arquivo .csv idêntico ao que recebeu, entretanto, com uma última coluna a mais, que é a coluna onde está efetivamente o resultado da predição para cada folha.

Ao final do processo o aplicativo mostra um mapa, baseado nas coordenadas geográficas de latitude e longitude que foram captadas durante a captura de cada imagem, com pontos representando cada folha e sua respectiva severidade, diferenciadas em níveis por cores, como mostra a Figura 37.

Figura 37 - Mapa gerado pelo aplicativo



Fonte: A autora.

O próprio *smartphone* fornece a opção para capturar a imagem da tela do aparelho e salvá-la, para que o usuário possa visualizar posteriormente outras vezes o mapa.

5. CONSIDERAÇÕES FINAIS

Apesar de encontrados trabalhos semelhantes, não foi constatado no levantamento literário realizado, nenhum estudo que fizesse uso da combinação de todas as características da pesquisa proposta, baseado em folhas de soja. O último trabalho mencionado no levantamento, Husin *et al* (2012), para o reconhecimento de folhas de ervas utilizando textura e forma via PDI para celular, aproxima-se no fato da utilização das duas tecnologias para um dispositivo móvel, o que trouxe motivação quanto aos rumos desta pesquisa.

Um fator que também deve ser observado e que exerce grande influência em todo o resultado da rede é a inserção correta dos dados, uma vez que em uma análise visual podem ocorrer imprecisões, por serem em faixas de valores muito semelhantes, o que também pode contribuir para possíveis erros no diagnóstico. Uma vez a entrada de dados esteja imprecisa, a rede neural receberá essa informação como correta e isso poderá comprometer o resultado final.

Esta rede neural foi treinada com mais de duas mil folhas de soja, assim, o aplicativo faz a predição com esta rede, sem a necessidade de que ela seja retreinada a cada foto tirada. Posteriormente, é possível coletar uma base de dados maior, com maior quantidade de folhas dentro dos níveis de severidade, visando manter a predição para os graus mais baixos de severidade, onde é mais interessante para o agricultor detectar a doença para tomar decisões o mais cedo possível, no início da infestação. Com a base de dados maior, basta realizar novamente o treinamento da rede, escolher a melhor alternativa, e novamente inseri-la no aplicativo, atualizada.

Poderão se beneficiar do sistema qualquer agricultor ou pessoa que possua um dispositivo *Android*, e isto os auxiliará na tomada de decisão em tempo real, dispensando a espera por uma resposta da análise do especialista. Ainda, opcionalmente, é possível obter o mapa com a localização georreferenciada das áreas afetadas em questão.

Como trabalhos futuros, é possível enxergar vários aperfeiçoamentos da pesquisa. Em primeiro lugar, vê-se a possibilidade de estudar a execução em ambiente não controlado, isto é, seria descartada a cúpula utilizada para a captura das imagens. Esta é uma questão desafiadora, devido às grandes dificuldades encontradas em trabalhar em ambientes não controlados, onde um único elemento, como por exemplo a luminosidade, pode mudar completamente o contexto da cena.

Uma melhoria fundamental para o trabalho é estudar, em conjunto com os construtores do robô, uma maneira de ligação mecânica para que a foto seja tirada apenas

após a certificação de que a cúpula se feche com a folha de soja dentro, tornando a coleta da imagem precisa.

Pode-se adaptar o objeto desta pesquisa para outras doenças de folhas, não necessariamente de soja, desde que possam ser visualmente identificadas, de modo a beneficiar produtores de diversas culturas no auxílio à prevenção e manejo de doenças precocemente, bem como fazer uso racional de insumos e produtos químicos para o controle das doenças.

É possível também, e mesmo desejável, desenvolver um estudo com foco direcionado para os simuladores de redes neurais. Este estudo teria por objetivo desenvolver um comparativo exaustivo de qual simulador traria melhores resultados em termos de assertividade na predição. Estariam sendo avaliadas suas mudanças de parâmetros e adaptação ao estudo, entretanto e sobretudo, todos os simuladores testados deveriam obrigatoriamente permitir implantar a rede neural treinada em um *smartphone*. Ainda nesta vertente, ao encontrar um simulador que demonstre resultados mais satisfatórios, poderia ser novamente realizada uma coleta de folhas, em escala algumas vezes maior que a realizada, para que a base de dados fosse multiplicada, e então fosse possível manter os níveis de predição mais baixos, tão importantes para o controle da doença.

Lembrando que este projeto é parte de um projeto maior, onde um robô realizará o percurso na plantação fazendo a captura das imagens, uma preparação para bluetooth é uma atualização importante para o aplicativo, pensando na praticidade e usabilidade do mesmo. O objetivo seria a ativação dos disparos para as fotos à distância.

Em se falando de *design*, um dos objetivos futuros é aprimorar a interface do aplicativo, de modo que fique mais intuitiva e elegante para os usuários finais.

Outra questão importante a ser considerada como um trabalho futuro é desenvolver uma versão do aplicativo para cada uma das principais plataformas disponíveis para celular hoje no mercado, como *Windows Phone* e *Iphone*, aumentando a portabilidade do produto e o alcance pelos usuários.

6. CONCLUSÕES

Como conclusões finais, tem-se que o trabalho alcançou o objetivo proposto, que era desenvolver um aplicativo para realizar o reconhecimento automático dos níveis de severidade da ferrugem asiática da soja.

No que se refere às tecnologias empregadas, a utilização da plataforma *Android* para desenvolvimento de aplicações para a realização de procedimentos de processamento digital de imagens com o auxílio da biblioteca *OpenCv* demonstrada no estudo, mostrou-se viável e eficaz, tornando-se uma tecnologia que traz várias possibilidades de aplicações práticas, como a própria aplicação apresentada no trabalho.

Quanto à aplicação do aprendizado de máquina através de redes neurais artificiais para o reconhecimento de padrões em imagens, pode-se concluir que as RNA's são eficazes para tal finalidade.

O pré-processamento da imagem é totalmente empírico. Ele influencia na extração de características, portanto deve haver cuidado direcionado à isto e devem ser realizados vários testes dos filtros que podem ou não ser aplicados, de modo que não prejudique, danifique ou distorça o significado da imagem e sua posterior extração de características.

Também se verificou, por consequência, que é necessário escolher de forma adequada os atributos que irão descrever a imagem, sendo este, um passo fundamental para uma rede com uma boa acurácia de aprendizado.

Referências

AGROLINK. Ferrugem asiática já causou prejuízos de US\$ 25 bi na lavoura de soja. 2014. Disponível em: <http://www.agrolink.com.br/noticias/ferrugem-asiatica-ja-causou-prejuizos-de-us--25-bi-na-lavoura-de-soja_170134.html>. Acesso em: 01 out. 2013.

AGROLINK. Soja. Ciclo e epidemiologia. 2014. Disponível em: <<http://www.agrolink.com.br/culturas/soja/cicloEpidemiologia.aspx>>. Acesso em: 17 Jul. 2014.

AGROLINK. Soja. Ferrugem. 2014. Disponível em: <<http://www.agrolink.com.br/culturas/soja/ferrugem.aspx>>. Acesso em: 17 jul. 2014.

AGROLINK. Soja. Mancha parda. 2014. Disponível em: <http://www.agrolink.com.br/culturas/soja/mancha-parda_1586.html>. Acesso em: 17 Jul. 2014.

AGROLINK. Soja. Sintomas. 2014. Disponível em: <<http://www.agrolink.com.br/culturas/soja/sintomas.aspx>>. Acesso em: 17 Jul. 2014.

AHONEN, T. *et al.* Recognition of Blurred Faces Using Local Phase Quantization. Proc. 19th International Conference on Pattern Recognition (ICPR 2008), Tampa, p. 1-4. 2008.

ALBUQUERQUE, V. *et al.* Sistema de segmentação de imagens para quantificação de microestruturas em metais utilizando redes neurais artificiais. Matéria (Rio J.), Rio de Janeiro, v. 12, n. 2, 2007. Disponível em <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1517-70762007000200018&lng=pt&nrm=iso>. Acesso em 10 out. 2013.

ANDROID. The Android Story. 2015. Disponível em: <<http://www.android.com/history/>>. Acesso em: 5 Jan. 2015.

APP ANNIE. App Annie & MEF: Emerging Markets and Growth in the Global App Economy. 2014. Disponível em: <<http://blog.appannie.com/app-annie-mef-global-app-economy-q3-2014/>>. Acesso em: 22 Out. 2014.

APPLE STORE. Apple Store. 2015. Disponível em: <<http://store.apple.com/br>>. Acesso em: 02 fev. 2015.

ARAUJO, L. M.; OLIVEIRA, F. L. Estudo dos descritores de características primitivas. In: ENCONTRO DE COMPUTAÇÃO E INFORMÁTICA DO TOCANTINS, 13., 2011, Palmas. Anais. Palmas: CEULP/ULBRA. p. 169-178. 2011. Disponível em: <http://www.bandalerda.com.br/wp-content/uploads/2011/11/Estudo_dos_descrito_res_de_caracteristicas_primitivas.pdf>. Acesso em: 19 Dez. 2014.

ARRIBAS, J. I. *et al.* Leaf classification in sunflower crops by computer vision and neural networks. Computers and Electronics in Agriculture, Espanha, v. 78, 2011. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169911001220>>. Acesso em: 12 out. 2013.

BARALDI, A.; PARMIGGIANI, F. An Investigation of the Textural Characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters – IEEE Transactions on Geoscience and Remote Sensing, 33(2), p.293–304. 1995.

BEALE, R; JACKSON, T. Neural Computing: na introduction. Bristol: Adam Hilger, 240 p. 1990.

BENDER, T.C. Classificação e Recuperação de Imagens por Cor Utilizando Técnicas de Inteligência Artificial. 126 f. Dissertação (Mestrado em Computação) – Departamento de Computação, UNISINOS, São Leopoldo, 2003.

BONDE MR, PETERSON GL. Research at the USDA, ARS Containment Facility on soybean rust and its causal agent. In: Sinclair JB, Hartman GL, editors. Proceedings of the Soybean Rust Workshop, 9–11 August 1995. College of Agricultural, Consumer, and Environmental Sciences, National Soybean Research Laboratory, Urbana, IL; 1996. p. 12–17.

BOTELHO, M. F; CENTENO, J. A. S. Integração de dados do laser scanner com a banda pan---cromática cromática do sensor QuickBird II do sensor QuickBird II QuickBird II para a identificação de edificações at para a identificação de edificações através das redes neurais numa abordagem orientação a regiões. Acta Scientarium, Maringá, v. 7, n. 1, 2005. Disponível em: < <http://periodicos.uem.br/ojs/index.php/ActaSciTechnol/article/view/1489/849>>. Acesso em: 03 out. 2013.

BRAGA, A. P., CARVALHO, A. C. P. L. F., LUDEMIR, T. B. Redes neurais artificiais: teoria e aplicações. LTC, 2007.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. RAE Eletronica, v.3, n.1, p. 2-20. 2004.

BRNeural, Projeto de pesquisa (Resolução CEPE - UEPG nº 065, de 27 de setembro de 2011).

BROMFIELD, K. R.; HARTWIG, E. E. Resistance to soybean rust and mode of inheritance. Crop Science, n. 20, p. 254-255, 1980.

C PROGRAMMING. Begin. 2015. Disponível em: <<http://www.cprogramming.com/begin.html>>. Acesso em: 03 jan. 2015.

CALDWELL, P.M.; McLAREN. Soybean rust reasearch in South África, pp. 354 - 360. In: WORLD SOYBEAN RESEARCH CONFERENCE, 7.; INTERNATIONAL SOYBEAN PROCESSING ANO UTILIZATION CONFERENCE, 4.; CONGRESSO BRASILEIRO DE SOJA, 3., 2004, Foz do Iguassu. Proceedings. Londrina: Embrapa Soybean, 2004. p.440-6. Editado por Flávio Moscardi, Clara Beatriz Hoffmann-Campo, Odilon Ferreira Saraiva, Paulo Roberto Galerani, Francisco Carlos Krzyzanowski, Mercedes Concordia Carrão-Panizzi.

CASTAÑÓN, C. A. B. Recuperação de Imagens por Conteúdo através de análises multiresolução por Wavelets. 112 p. Dissertação (Mestrado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos. 2003.

CHAGAS, C. S. *et al.* Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. *Revista Brasileira de Engenharia Agrícola Ambiental*, Campina Grande, v. 13, n. 3, 2009. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662009000300014&lng=en&nrm=iso>. Acesso em: 12 out. 2013.

CONAB. Acompanhamento da Safra Brasileira – Grãos. 2014. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/14_08_07_08_59_54_boletim_graos_agosto_2014.pdf>. Acesso em: 15 dez. 2014.

CONAB. Séries Históricas. 2013. Disponível em: <http://www.conab.gov.br/conteudos.php?a=1252&&Pagina_objcmsconteudos=3#A_objcmsconteudos>. Acesso em: 02 dez. 2013.

CONCI, A.; AZEVEDO, E.; LETA, F. R. *Computação Gráfica – Teoria e Prática*. Rio de Janeiro, Editora Campus/Elsevier. Vol. 2. 432 páginas. 2008.

CONSÓRCIO ANTIFERRUGEM. Conheça a ferrugem – tabela de custos. 2012. Disponível em: <<http://www.consorcioantiferrugem.net>>. Acesso em: 12 out. 2013.

CRCAMPEIRO. Projeto CR Campeiro. 2015. Disponível em: <<http://www.crcampeiro.net/novo/>>. Acesso em: 03 fev. 2015.

CYBENKO, George. Approximation by superpositions of sigmoid function. *Mathematics of Control, Signals and Systems*, 2:303-314. 1989. Disponível em: http://www.dartmouth.edu/~gvc/Cybenko_MCSS.pdf. Acesso em 22 Out. 2014.

CUI, D., Zhang, Q.; Li, M.; Zhao, Y.; Hartman, G. L. Detection of soybean rust using a multispectral image sensor. *Sens. & Instrumen. Food Qual.* 3:49–56. 2009.

DEL BIMBO, A. *Visual Information Retrieval*. São Francisco: Morgan Kaufmann Publishers, 208 p. 1999.

DEMO, P. *Pesquisa e construção de conhecimento*. Rio de Janeiro: Tempo Brasileiro, 1996.

DESLANDES, J. A. Ferrugem da soja e de outras leguminosas causadas por *Phakopsora pachyrhizi* no Estado de Minas Gerais. *Fitopatologia Brasileira*, Brasília, v. 4, n. 2, p. 337-339, 1979.

DESLAURIERS J.P. *Recherche qualitative; guide pratique*. Québec (Ca): McGraw Hill, Éditeurs, 1991.

EMBRAPA SOJA. A soja em números. 2013. Disponível em: <http://www.cnpso.embrapa.br/index.php?cod_pai=2&op_page=294>. Acesso em: 29 Set. 2013.

EMBRAPA SOJA. A soja no Brasil. 2014. Disponível em: <http://www.cnpso.embrapa.br/producaosoja/SojanoBrasil.htm>. Acesso em: 14 Jul. 2014.

EMBRAPA SOJA. Doenças e medidas de controle. 2013. Disponível em: <<http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Soja/SojaCentralBrasil2002/doenca.htm>>. Acesso em: 01 out. 2013.

EMBRAPA SOJA. Doenças. 2013. Disponível em: <<http://www.cnpso.embrapa.br/producao soja/doenca.htm>>. Acesso em: 14 Jul. 2014.

ENCOG. Encog Machine Learning Framework. 2015. Disponível em: <<http://www.heatonresearch.com/encog>>. Acesso em: 02 fev. 2015.

ENGESAT. Satélites. Aster. 2014. Disponível em: <<http://www.engesat.com.br/satelites/aster/>> Acesso em: 12 fev. 2014.

ESCOBAR, L; PONTI JR., M. P. 2013. Quantização de imagens para geração de descritores compactos de cor e textura. Conference on Graphics, Patterns and Images, 2012.

FAEMG. CNA estima crescimento de 8,4% no VBP em 2014. 2014. Disponível em: <<http://www.faeng.org.br/Noticia.aspx?Code=6450&ContentVersion=C&Show=all>>. Acesso em: 15 dez. 2014.

FAHLMAN, S. E. Faster-Learning Variations on Back-Propagation: An Empirical Study, In: Proceedings, Connectionist Models Summer School, Morgan-Kaufmann, Los Altos CA. 1998.

FAPCEN. Notícias; Ferrugem asiática causa prejuízos de US\$ 8 bilhões em MT. 2014. Disponível em: <http://www.fapcen.agr.br/?p=80>. Acesso em: 14 Jul. 2014.

FMC. Aplicativo FMC Agrícola Brasil. 2015. Disponível em: <<https://www.fmcagricola.com.br/imprensareleasesdetalhes.aspx?cod=166>>. Acesso em 03. fev. 2015.

FREITAS, A. A. C.; SILVA, I. N.; SOUZA, A. N. Aplicação de redes neurais na estimação da temperatura interna de transformadores de distribuição imersos em óleo. Sba Controle & Automação, Campinas, v.13, n.3. 2002. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592002000300005&lng=en&nrm=iso>. Acesso em: 02 Dez. 2013.

GEGENFURTNER, K.R. e SHARPE, L.T. Color Vision: from genes to perception. United Kingdom: Cambridge University Press. 492p. 2000.

GONÇALVES, K. S.; CASTRO, H. A.; HACON, S. S. As queimadas na região amazônica e o adoecimento respiratório. Ciência e Saúde Coletiva, Rio de Janeiro, v. 17, n. 6, 2012. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-81232012000600016&lng=en&nrm=iso>. Acesso em: 10 out. 2013.

GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing. Prentice Hall, 2002.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, Steven L. Digital image processing using Matlab. Uppler Saddle River: Prentice Hall. 609p. 2004.

GONZALEZ, R. C.; WOODS, R. E. Processamento Digital de Imagens. Pearson, 2010.

GONZALEZ, R. C.; WOODS, R. E. Digital image processing. Reading, MA: AddisonWesley, 716p. 1992.

GOOGLE PLAY. Google play. 2015. Disponível em: <https://play.google.com/store?hl=pt_BR>. Acesso em: 02 fev. 2015.

GRUPO CULTIVAR. Artigos Técnicos. Bactérias atacam a soja. 2014. Disponível em: <<http://www.grupocultivar.com.br/site/content/artigos/artigos.php?id=476>>. Acesso em: 17 Jul. 2014.

GRUPO CULTIVAR. Ferrugem chegará mais cedo na safra 12/13. 2014. Disponível em: <<http://www.grupocultivar.com.br/site/content/noticias/?q=29735>>. Acesso em: 17 Jul. 2014.

HAYKIN, S. Redes neurais princípios e prática. Porto Alegre, Bookman, 900p, 2001.

HAYKIN, S. Redes YKIN, S. Redes Neurais Princípios e Prática. Porto Alegre, Bookman, 2001, 900p.

HENNEN, J.F .. The taxonomy of the rusts. In: RUST WORKSHOP, Urbana. 1995. Proceedings. Urbana: College of Agricultural, Consumer, and Environmental Sciences: National Soybean Research Laboratory, p.29-32, 1996. (Publication Number 1) Editado por J.B. Sinclair, G.L. Hartman.

HUSIN, Z. *et al.* Embedded portable device for herb leaves recognition using image processing techniques and neural network algorithm. Computers and Electronics in Agriculture, Malasya, v. 89, 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169912001949>>. Acesso em: 12 out. 2013.

IOS. IOS 8. 2015. Disponível em: <<https://www.apple.com/br/ios/>>. Acesso em: 02 fev. 2015.

ITO, R., KIM, H., SALCEDO, W. Classificação de Texturas Invariante a Rotação Usando Matriz de Coocorrência. In: 8th International Information and Telecommunication Technologies Symposium. 2009.

JACCOUD FILHO, D.S.; *et al.* Ocorrência da Ferrugem da Soja na Região dos Campos Gerais do Paraná. In: Resumos XXIII. Reunião de Pesquisa de Soja da Região Central do Brasil. Anais. Londrina, PR, p. 109. 2001.

JACCOUD FILHO, D. S. ; PASSINI, F. B. ; DABUL, A.N ; GRANADO, CARLOS J.F. ; FIGUEREDO, M. . Alternatives Hosts of the Agent of the Asian Soybean Rust (*Phakopsora pachyrhizi*) in Brazil. Fitopatologia Brasileira , v. 32, p. 60-64. 2007.

JACCOUD FILHO, D. S. Hospedeiros alternativos do agente causal no Brasil. 40º Congresso Brasileiro de Fitopatologia. Maringá, Paraná. Palestra. 2007.

JAVA. Java Platform. 2015. Disponível em: <<https://www.oracle.com/java/technologies/java-se.html>>. Acesso em: 03 jan. 2015.

JAVANNS. JavaNNS: Java Neural Network Simulator. 2015. Disponível em: < <http://www.ra.cs.uni-tuebingen.de/software/JavaNNS/>>. Acesso em: 02 fev. 2015.

JOHANN, J. A. *et al.* Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. Pesquisa Agropecuária Brasileira, Brasília, v. 47, n. 9, 2012.

KAWUKI, R.S.; ADIPALA, E; TUKUMUHABWA, P.. Yield loss associated with soya bean rust (*Phakopsora pachyrhizi* Syd.) in Uganda. Journal of Phytopathology, v. 151, p.7-12, 2003.

KHATCHATOURIAN O., PADILHA, F. R. R. Reconhecimento de Variedades de Soja por meio do Processamento de Imagens Digitais Usando Redes Neurais Artificiais. Engenharia Agrícola, Jaboticabal, v.28, n.4, p.759-769, 2008. Disponível em: <http://www.scielo.br/scielo.php?pid=S0100-91622008000400016&script=sci_abstract&tlng=pt>. Acesso em: 12 out. 2013.

KILLGORE, E. M. Field notes on the detection of soybean rust. initial surveys and the current status of the disease in Hawaii,. In: RUST WORKSHOP, Urbana, 1995. Proceedings. Urbana: College of Agricultural, Consumer, and Environmental Sciences: National Soybean Research Laboratory, 1996. p.38-45 (Publication Number 1) Editado por J.B. Sinclair, G. L. Hartman.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: International joint Conference on artificial intelligence. v. 14, p. 1137–1145. 1995.

LECHETA, Ricardo R. Google Android: aprenda a criar aplicações para dispositivos móveis com o Android SDK. 3ª ed. São Paulo. Novatec Editora, 2013.

LEVY, C. Zimbabwe - a country report on soybean rust control, pp. 340-348. In: In: WORLD SOYBEAN RESEARCH CONFERENCE, 7.; INTERNATIONAL SOYBEAN PROCESSING AND UTILIZATION CONFERENCE, 4.; CONGRESSO BRASILEIRO DE SOJA, 3., 2004, Foz do Iguassu. Proceedings ... Londrina: Embrapa Soybean, p.361-364. 2004. Editado por Flávio Moscardi, Clara Beatriz Hoffmann-Campo, Odilon Ferreira Saraiva, Paulo Roberto Galerani, Francisco Carlos Krzyzanowski, Mercedes Concordia Carrão-Panizzi.

MARQUES FILHO, O.; VIEIRA NETO, H.. Processamento Digital de Imagens, Rio de Janeiro: Brasport, 1999.

MATLAB. MatLab. 2015. Disponível em: < <http://www.mathworks.com/products/matlab/>>. Acesso em: 03 fev. 2014.

MATHIAS, I. M. Aplicação de redes neurais artificiais na análise de dados de molhamento foliar por orvalho. 120 f. Tese de Doutorado. Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas. Botucatu, São Paulo. 2006.

MATTIAZZI, P. Efeito do oídio (*Microsphaera diffusa* Cooke & Peck) na produção e duração da área foliar sadia da soja. (Dissertação de mestrado). Piracicaba. Escola Superior de Agricultura Luiz de Queiroz. 2003.

MINAYO, M. C. S. O desafio do conhecimento. Pesquisa qualitativa em saúde. São Paulo: HUCITEC, 2007.

MOREL PAIVA, W .. Roya de la soja. Itapúa: Ministerio de Agricultura y Ganaderia, Subsecretaria de Agricultura, Dirección de Investigación Agrícola: Centro Regional de Investigación Agrícola - CRIA (Comunicado Técnico - Reporte Oficial, Série Fitopatología, 1). 2001.

NASCIMENTO, J. P. R. Análise e classificação de imagens baseada em características de textura utilizando matrizes de coocorrência. 116 p. Dissertação (Programa de Pós-Graduação em Informática, Setor de Ciências Exatas) – Universidade Federal do Paraná, Curitiba. 2003

NET APPLICATIONS. Mobile/Tablet Top Operating System Share Trend. 2015. Disponível em: <<http://www.netmarketshare.com/operating-system-market-share.aspx?qprid=9&qpcustomb=1&qpct=4&qpdp=175&qppn=12&qptimeframe=M>>. Acesso em: 03 jan. 2015.

NEUROPH. Neuroph Java Neural Network Framework. 2015. Disponível em: <<http://neuroph.sourceforge.net/>>. Acesso em: 02 fev. 2015.

OLIVEIRA BATISTA, J. L.; LEAL SANTOS, R. Análise da dinâmica do uso e ocupação da terra em pequenos municípios baianos do semi-árido brasileiro: o caso de Teofilândia. Revista de Geografia Norte Grande, Santiago, n. 49, 2011 . Disponível em <http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-34022011000200009&lng=es&nrm=iso>. Acesso em: 10 out. 2013.

ONO, Y., BURITICÁ, P. & HENNEN, J.F. Delimitation of *Phakopsora*, *Physopella*, and *Cerotelium* and their species on Leguminosae. *Mycological Research* 96:825-850. 1992.

ONU. Dos 7 bilhões de habitantes do mundo, 6 bi têm celulares, mas 2,5 bi não têm banheiros. 2013. Disponível em: <<http://nacoesunidas.org/onu-dos-7-bilhoes-de-habitantes-do-mundo-6-bi-tem-celulares-mas-25-bi-nao-tem-banheiros/>>. Acesso em: 06 Jul. 2013.

ONU. Até final de 2014, 3 bilhões de pessoas serão usuárias da internet, afirma novo relatório da ONU. 2014. Disponível em: <<http://nacoesunidas.org/ate-final-de-2014-3-bilhoes-de-pessoas-serao-usuarios-da-internet-afirma-novo-relatorio-da-onu/>>. Acesso em: 14 Jul. 2014.

OPENCV. About. 2013. Disponível em: <<http://opencv.org/about.html>>. Acesso em: 13 set. 2013.

OPEN STD. C. 2015. Disponível em: <<http://www.open-std.org/jtc1/sc22/wg14/>> Acesso em: 03 jan. 2015

OPEN STD. C++. 2015. Disponível em: <<http://www.open-std.org/JTC1/SC22/WG21/>> Acesso em: 03 jan. 2015.

OSHIRO, S. H.; GOLDSCHMIDT, R. R. Processamento de Imagens. 23 p. Monografia (Graduação em Sistemas e Computação) – Seção de Engenharia de Computação, Instituto Militar de Engenharia, Rio de Janeiro. 2008.

PASSINI, F., B. Ferrugem Asiática (*Phakopsora pachyrhizi*) da soja (*Glycines max.*) na cultura do feijão (*Phaseolus vulgaris*). 79 f. Dissertação (Mestrado em Agronomia) – Grupo de Fitopatologia Aplicada, UEPG, Ponta Grossa. 2007.

PATIL, S. B.; BODHE, S. K. Leaf disease severity measurement using image processing. International Journal of Engineering and Technology Vol.3 (5), 297-301. 2011.

PEDRINI, H.; SCHWARTZ, W. R. Análise de Imagens Digitais, São Paulo, Thomson. 508p. 2008.

PENATTI, O. A. B.; VALLE, E.; TORRES R. S., Comparative study of global color and texture descriptors for web image retrieval, Journal of Visual Communication and Image Representation, vol. 23, no. 2, pp. 359–380. 2012.

PIRES, P. C.; FERNANDES, J. M. C.; NICOLAU, M. Modelagem do progresso temporal e do padrão espacial de lesões de ferrugem da folha em trigo. Tropical Plant Pathology, Brasília, v. 34, n. 2. 2009.

PONTI JR., M. P. Segmentation of low-cost remote sensing images combining vegetation indices and mean shift. IEEE Geoscience and Remote Sensing Letters, 2012.

PRETORIUS, Z.A.; KLOPPERS, R.J.; FREDERICK, R.D. .. First report of soybean rust in South Africa. Plant Disease, v. 85, p.1288. 2001.

PYTHOM. Pythom. 2015. Disponível em: < <https://www.python.org/>>. Acesso em: 03 jan. 2015.

RAMOS, J. P. S. Redes neurais artificiais na classificação de frutos: cenário bidimensional. Ciência e Agrotecnologia, v.27, n.2, p.356-362. 2003.

ROGENSKI, R. A. *et al.* Aplicação de Redes Neurais Artificiais para a Estimativa de Infecção dor Manchas Foliares na Cultura do Trigo. Revista de Engenharia e Tecnologia, Ponta Grossa, vol. 4, n. 2, 2012. Disponível em: < <http://www.revistaret.com.br/ojs-2.2.3/index.php/ret/article/view/122>>. Acesso em: 12 out. 2013.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Reviews, 65: 386-408. 1958.

RUMELHART, David Everett; MCCLELLAND, James Lloyd. Parallel Distributed Processing. Foundations. The MIT Press. Vol. 1. 1986. Disponível em: <http://psych.stanford.edu/~jlm/papers/PDP/Volume%201/>. Acesso em: 22 Out. de 2014.

RUSSELL, S.; NORVIG, P. Inteligência Artificial. Elsevier, 2004

SALDANA, Erick *et al.* Computer vision applied to the inspection and quality control of fruits and vegetables. Braz. J. Food Technol., Campinas, v. 16, n. 4, p. 254-272. 2013.

Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1981-67232013000400002&lang=pt>. Acesso em: 02 fev. 2015.

SARTORATO, A.; YORINORI, J. T. Oídios de leguminosas: feijoeiro e soja. In: Standnick, M. J.; Rivera, M. C. Oídios. Jaguariúna: Embrapa Meio Ambiente, p. 255-284. 2001.

SCHWARTZ, S.H. Visual Perception: a clinical orientation. Segunda edição. Library of Congress, USA, 433p. 1999.

SCHWARTZ, W.R.; PEDRINI, H. Método para Classificação de Imagens Baseada em Matrizes de Co-ocorrências utilizando Características de Textura. In: COLÓQUIO BRASILEIRO DE PESQUISAS GEODÉSICAS, 2003.

SENA JUNIOR, D. G. *et al.* Algoritmo para classificação de plantas de milho atacadas pela lagarta do cartucho (*Spodoptera frugiperda*, Smith) em imagens digitais. Revista Brasileira de Engenharia Agrícola Ambiental, Campina Grande, v. 5, n. 3, 2001. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662001000300023&lng=en&nrm=iso>. Acesso em: 12 out. 2013.

SIGLA. SIGLA - Sistema de Informações Gerenciais para Lab. de Resíduos e Contam. em Alimentos. 2015. Disponível em: <<http://sistemasweb.agricultura.gov.br/pages/SIGLA.html>>. Acesso em: 03 fev. 2015.

SINCLAIR, J.B.; HARTMAN, G.L. Soybean rust. In: HARTMAN, G.L.; SINCLAIR, J.B.; RUPE, J.C. (Ed.). Compendium of soybean diseases. 4. ed. Saint Paul: APS Press, p. 25-26. 1999.

SISTEMA DE ALERTA. Embrapa Soja. Sintomas da Ferrugem. 2014. <<http://www.cnpso.embrapa.br/download/verso.jpg>>. Acesso em: 17 Jul. 2014.

SOCIEDADE NACIONAL DE AGRICULTURA. Ferrugem asiática avança e deixa produtores em alerta. 2014. Disponível em: <http://sna.agr.br/ferrugem-asiatica-avanca-e-deixa-produtores-em-alerta/>. Acesso em: 15 Jul. 2014.

SUO, X. *et al.* Artificial Neural Network to Predict Leaf Population Chlorophyll Content from Cotton Plant Images. Agricultural Sciences in China, China, v. 9, 2009. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1671292709600651>>. Acesso em: 12 out. 2013.

TORRES, R.; FALCÃO, A.; DINSTEIN, I. Content-Based Image Retrieval: Theory and Applications. Revista de Informática Teórica e Aplicada, v. 13, n. 2, p. 161-185. 2006.

VAKILI, N.G.; BROMFIELD, K.R. Phakopsora rust on soybean and other legumes in Puerto Rico. Plant Disease Reporter, v.60, p.995-9. 1976.

VARELLA, C. A. A. *et al.* Determinação da cobertura do solo por análise de imagens e redes neurais. Revista Brasileira de Engenharia Agrícola Ambiental, Campina Grande, v. 6, n. 2, 2002. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662002000200007&lng=en&nrm=iso>. Acesso em: 12 out. 2013.

VERONEZI, C. C. D. *et al.* Análise computacional para auxílio ao diagnóstico de osteoartrite de coluna lombar baseado em redes neurais artificiais. Revista Brasileira de Ortopedia, São Paulo, v. 46, n. 2, 2011. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-36162011000200014 &lng=en&nrm=iso>. Acesso em: 10 out. 2013.

WEIZHENG, S.; YACHUN, W.; ZHANLIANG, C.; HONGDA, W. Grading method of leaf spot disease based on image processing. In: Proceedings of the 2008 international conference on computer science and software engineering, CSSE. IEEE Computer Society, Washington, DC, vol. 06, pp. 491-494. 2008.

WEKA. Weka 3: Data Mining Software in Java. 2015. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 02 fev. 2015.

WIDROW, Bernard; HOFF, Marcian. Adaptive switching circuits. Institute of Radio Engineers, Western Electronic Show and Convention. 1960. Disponível em: <http://www-isl.stanford.edu/~widrow/papers/c1960adaptiveswitching.pdf>. Acesso em: 22 Out. 2014.

WINDOWS PHONE. Windows Phone. 2015. Disponível em: <<http://www.windowsphone.com/pt-br>>. Acesso em: 02 fev. 2015.

WINDOWS PHONE STORE. Windows Phone. 2015. Disponível em: <<http://www.windowsphone.com/pt-br/store>>. Acesso em: 02 fev. 2015.

YARA BRASIL. Yara CheckIt. 2015. Disponível em: <<http://www.yarabrasil.com.br/nutricao-plantas/ferramentas-servicos/yara-checkit-app/>>. Acesso em: 03 fev. 2015.

YORINORI, J. T. Epidemiologia e controle de *Phakopsora pachyrhizi*, safra 1987/88. In: EMBRAPA. Centro Nacional de Pesquisa de Soja. Resultados de pesquisa de soja 1988/89. Londrina: EMBRAPA CNPSo, p. 164-180. 1989.

YORINORI, J. T.; DESLANDES, J. A. The status of soybean rust in Brazil. In: WORLD SOYBEAN RESEARCH CONFERENCE, 3, Ames. Program and abstracts. Ames: Iowa State University, p. 43-44. 1984.

YORINORI, J.T. Country report and rust control strategies in Brazil. In: WORLD SOYBEAN RESEARCH CONFERENCE, 7.; INTERNATIONAL SOYBEAN PROCESSING AND UTILIZATION CONFERENCE, 4.; CONGRESSO BRASILEIRO DE SOJA, 3. Foz do Iguaçu. Proceedings. Londrina: Embrapa Soybean, 2004. p. 447-455. Editado por Flávio Moscardi, Clara Beatriz Hoffmann-Campo, Odilon Ferreira Saraiva, Paulo Roberto Galerani, Francisco Carlos Krzyzanowski, Mercedes Concordia Carrão-Panizzi. 2004.

YORINORI, J.T.; GODOY, C.V.; PAIVA, W. M.; FREDERICK, R.D.; COSTAMILAN, L.M.; BERTAGNOLLI, P.F.; NUNES JUNIOR, J. Evolução da ferrugem da soja (*Phakopsora pachyrhizi*) no Brasil, de 2001 a 2003. Fitopatologia Brasileira, v.28, p.S21 O. 2003.

YORINORI, J. T; PAIVA, W. M; FREDERICK, R.D. & FERNANDEZ, P.F.T. Ferrugem da soja (*Phakopsora pachyrhizi*) no Brasil e no Paraguai, nas safras 2000/01 e 2001/02. Anais, Congresso Brasileiro de Soja, Foz do Iguaçu, p. 94. 2002.

YORINORI, J.T.; PAIVA, W.M.; FREDERICK, R.D.; COSTAMILAN, L.M.; BERTAGNOLLI, P.F.; HARTMAN, G.L.; GODOY, C.V.; NUNES JUNIOR, J. Epidemics of soybean rust (*Phakopsora pachyrhizi*) in Brazil and Paraguay. *Plant Disease*, v.89, p. 675-677, 2005.

ZHAN, Y. L. *et al.* Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, China, v. 72, 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169910000712>>. Acesso em: 12 out. 2013.