


UNIVERSIDADE FEDERAL DO PARANÁ

ANTONIO CIPRIANO BISPO NETO
ARTHUR JOSE ANTOCEVICZ POLLI

IDENTIFICAÇÃO DO PERCEVEJO MARROM EM IMAGENS ATRAVÉS DA
TÉCNICA MÁQUINA DE VETORES DE SUPORTE (SVM)

CURITIBA

2019



ANTONIO CIPRIANO BISPO NETO
ARTHUR JOSE ANTOCEVICZ POLLI

IDENTIFICAÇÃO DO PERCEVEJO MARROM EM IMAGENS ATRAVÉS DA
TÉCNICA MÁQUINA DE VETORES DE SUPORTE (SVM)

Projeto final apresentado ao curso de Graduação
em Eng. Cartográfica e de Agrimensura,
Departamento de Geomática, Setor de Ciências da
Terra, Universidade Federal do Paraná.

Orientador: Prof. Dr. Hideo Araki

Coorientador: Prof. Dr. Thiago Ranzan

CURITIBA

2019

TERMO DE APROVAÇÃO

ANTONIO CIPRIANO BISPO NETO
ARTHUR JOSE ANTOCEVICZ POLLI

IDENTIFICAÇÃO DO PERCEVEJO MARROM EM IMAGENS ATRAVÉS DA TÉCNICA MÁQUINA DE VETORES DE SUPORTE (SVM)

Trabalho Final de Conclusão de Curso apresentado ao curso de Engenharia Cartográfica e de Agrimensura, em 06 de dezembro de 2019, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia Cartográfica e de Agrimensura.

Prof(a). Dr(a)./Msc. _____

Orientador(a) – Departamento _____, INSTITUIÇÃO

Prof(a). Dr(a)./Msc. _____

Departamento _____, INSTITUIÇÃO

Prof(a). Dr(a)./Msc. _____

Departamento _____, INSTITUIÇÃO

Cidade, ___ de _____ de 201_.

Mantenha essa página em branco para inclusão do termo/folha de aprovação assinado e digitalizado.

RESUMO

Por conta de sua extensão territorial o Brasil proporciona uma ampla gama de atividades econômicas, sendo uma das mais importantes atividades do setor primário é a produção agrícola, em especial a da soja, que lidera o ranking de produção agrícola. Dentre as pragas da soja as mais importantes são os percevejos fitófagos, os quais afetam seriamente o rendimento e a qualidade da cultura da soja, por se alimentarem dos seus grãos. Atualmente existem diversos métodos para amostragem e quantificação de insetos-praga, entretanto são todos métodos manuais, o que acarreta em custos e também torna o método dependente da capacidade cognitiva humana que pode acarretar na imprecisão da quantificação das pragas. Este trabalho tem como objetivo desenvolver um algoritmo de Identificação do Percevejo marrom em imagens embasado na técnica Support Vector Machine (SVM), com o intuito de fomentar a criação de ferramentas tecnológicas para a detecção do percevejo marrom em lavouras. Para a implementação da base de dados, primeiramente, foram criados diferentes cenários, com o objetivo de obter diferentes planos de fundo e diferentes condições de iluminação, onde o percevejo marrom, foi fotografado com diferentes distâncias, inclinações e rotações. Com o objetivo de obter uma nova solução para o presente projeto, todas as imagens coletadas passaram por um processo de transformação RGB para HSV, das quais foram aproveitadas somente a banda H (Matiz). A banda Matiz foi escolhida por distinguir de maneira mais homogênea todos os objetos presentes na imagem. Após a transformação das fotografias foram selecionadas imagens de treinamento para o algoritmo, nas quais os percevejos foram selecionados com o intuito de extrair suas fotocoordenadas e fornecer amostras classificadas para o algoritmo. Com as amostras dos percevejos e suas respectivas informações RGB e H o algoritmo SVM foi gerado para a detecção dos percevejos. Avaliando os resultados obtidos na etapa de identificação do percevejo, foi possível notar que os resultados utilizando as imagens referentes à banda Matiz foram os melhores.

Palavras-chave: Percevejo Marrom, Agricultura de precisão, Aprendizado de máquina, SVM, Processamento digital de imagens.

ABSTRACT

Due to its territorial extension, Brazil provides a wide range of economic activities. One of the most important activities in the primary sector is agricultural production, especially soybean, which leads the ranking of agricultural production. Among the soybean pests, the most important are the phytophagous bedbugs, which seriously affect the yield and the quality of the soybean crop, as they feed on its grains. Currently there are several methods for sampling and quantification of pest insects, however they are all manual methods, which entails costs and also makes the method dependent on human cognitive capacity that may cause inaccuracy in pest quantification. This work aims to develop a brown stink bug identification algorithm based on the Support Vector Machine (SVM) technique, in order to foster the creation of technological tools for the detection of brown stink bug in crops. For the implementation of the database, firstly, different scenarios were created in order to obtain different backgrounds and different lighting conditions, where the brown stink bug was photographed with different inclination, rotation and distances. In order to obtain a new solution for the present paper, all the images collected underwent an RGB to HSV transformation process, from which only the H band (Hue) was used. The band Hue was chosen for distinguishing more homogeneously all the objects present in the image. After the transformation of the photographs, training images were selected for the algorithm, in which the bed bugs were selected in order to extract their photocoordinates and provide classified samples for the algorithm. With the bed bug samples and their respective RGB and H information, the SVM algorithm was generated for bed bug detection. Evaluating the results obtained in the bed bug identification step, it was observed that the results using the images related to the Hue band were the best.

Key-Words: Brown stink bug, Precision agriculture, Machine learning, SVM, Digital image processing.

LISTA DE FIGURAS

FIGURA 1 – RESULTADO DA PRODUÇÃO VEGETAL NACIONAL DE 2017.....	20
FIGURA 2 - PERCEVEJO MARROM NA VAGEM DE SOJA.....	21
FIGURA 3 - ILUSTRAÇÃO DO MÉTODO PANO-DE-BATIDA	22
FIGURA 4 - EXEMPLO HIERÁRQUICO DE TAREFAS DE PROCESSAMENTO DE IMAGENS.....	24
FIGURA 5 - ESQUEMA DE APRENDIZADO DE MÁQUINA	25
FIGURA 6 - DIFERENTES SOLUÇÕES PARA AS AMOSTRAS.....	26
FIGURA 7 - ESPECTRO ELETROMAGNÉTICO	27
FIGURA 8 - PRINCÍPIO SVM E HIPERPLANO	29
FIGURA 9 - CÂMERA FOTOGRAFICA SONY DSC-HX300.....	30
FIGURA 10 - EXEMPLO DAS AMOSTRAS CONTIDAS NO LABORATÓRIO	30
FIGURA 11 - PEPARAÇÃO DO CENÁRIO.....	32
FIGURA 12 - VISTA ÁREA DE PORÇÃO DO CAMPUS CENTRO POLITÉCNICO .	33
FIGURA 13 - EXEMPLO DE PREPARO DO CENÁRIO AO AR LIVRE	34
FIGURA 14 - EXEMPLO DE FOTOGRAFIA TOMADA SOB ISOPOR	35
FIGURA 15 - EXEMPLO DE FOTOGRAFIA TOMADA SOB PAPELÃO.....	35
FIGURA 16 - EXEMPLO DE FOTOGRAFIA TOMADA SOB FOLHA DE PAPEL.....	35
FIGURA 17 - EXEMPLO DE FOTOGRAFIA TOMADA SOB FOLHA VEGETAL.....	36
FIGURA 18 - EXEMPLO DE FOTOGRAFIA TOMADA AO AR LIVRE	36
FIGURA 19 – PRIMEIRO EXEMPLO DA TRANSFORMAÇÃO PARA A BANDA MATIZ	37
FIGURA 20 – SEGUNDO EXEMPLO DA TRANSFORMAÇÃO PARA A BANDA MATIZ	38
FIGURA 21 - EXEMPLO DA SELEÇÃO DO OBJETO EM IMAGENS DE TREINAMENTO	39
FIGURA 22 - RESULTADO OBTIDO NO ITEM 4.1.1	41
FIGURA 23 - RESULTADO OBTIDO NO ITEM 4.1.2	42
FIGURA 24 - RESULTADO OBTIDO NO ITEM 4.2.1	44
FIGURA 25 - RESULTADO OBTIDO NO ITEM 4.2.2	45
FIGURA 26 - RESULTADO OBTIDO NO ITEM 4.5	46
FIGURA 27 - RESULTADO OBTIDO NO ITEM 4.6	47

LISTA DE GRÁFICOS

GRÁFICO 1 – TAXA DE DETÇÃO.....	48
GRÁFICO 2 - ACURÁCIA	48
GRÁFICO 3 - ÁREA MÍNIMA	49

LISTA DE TABELAS

TABELA 1 - RESULTADOS EM LABORATÓRIO: IMAGENS RGB.....	41
TABELA 2 - RESULTADOS EM LABORATÓRIO: IMAGENS MATIZ.....	42
TABELA 3 - RESULTADOS COM PLANO DE FUNDO DE FOLHAS VEGETAIS: IMAGENS RGB.....	43
TABELA 4 - RESULTADOS COM PLANO DE FUNDO DE FOLHAS VEGETAIS: IMAGENS MATIZ.....	44
TABELA 5 - RESULTADOS AO AR LIVRE: IMAGENS RGB.....	45
TABELA 6 - RESULTADOS AO AR LIVRE: IMAGENS MATIZ.....	46

LISTA DE ABREVIATURAS OU SIGLAS

SVM	- <i>Support Vector Machine</i>
PDI	- Processamento Digital de Imagens
ML	- Machine Learning
RGB	- Red, Green and Blue
HSV	- Hue, Saturation and Value

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVO GERAL	17
1.1.1 Objetivos Específicos	18
1.2 JUSTIFICATIVA	18
2 REVISÃO DE LITERATURA	19
2.1 CULTURA DA SOJA	19
2.2 PERCEVEJO MARROM	20
2.3 MÉTODO PANO-DE-BATIDA	21
2.4 AGRICULTURA DE PRECISÃO	22
2.5 PROCESSAMENTO DIGITAL DE IMAGENS	23
2.6 BANDA MATIZ (HSV).....	26
2.7 MÁQUINA DE VETORES DE SUPORTE (SVM – SUPORT VECTOR MACHINE)	
28	
3 METODOLOGIA	29
3.1 MATERIAIS	29
3.1.1 CAMERA.....	30
3.1.2 AMOSTRAS DE PERCEVEJO MARROM	30
3.1.3 SOFTWARES.....	30
3.1.4 HARDWARE	31
3.1.5 CENÁRIOS DE TESTE	31
3.1.5.1 PRIMEIRO CENÁRIO: FOTOGRAFIAS EM LABORATÓRIO.....	32
3.1.5.2 SEGUNDO CENÁRIO: FOTOGRAFIAS AO AR LIVRE	33
3.2 TOMADA DAS FOTOGRAFIAS	34
3.2.1 TOMADA DAS FOTOGRAFIAS EM LABORATÓRIO.....	34
3.2.2 TOMADA DAS FOTOGRAFIAS AO AR LIVRE.....	36
3.3 TRANSFORMAÇÃO DAS IMAGENS.....	37
3.4 IMAGENS DE TREINAMENTO.....	38
3.5 TREINAMENTO E IMPLEMENTAÇÃO ALGORITMO SVM.....	39
3.6 EXPERIMENTOS E ANÁLISES DE RESULTADO	40
4 RESULTADOS E DISCUSSÕES	40
4.1 FOTOGRAFIAS EM LABORATÓRIO COM DIFERENTES PLANOS DE FUNDO	

4.1.1	Imagens RGB.....	41
4.1.2	IMAGENS MATIZ	41
4.2	LABORATÓRIO COM FOLHAS VEGETAIS COMO PLANOS DE FUNDO.....	43
4.2.1	IMAGENS RGB	43
4.2.2	IMAGENS MATIZ	44
4.3	FOTOGRAFIAS TOMADAS AO AR LIVRE.....	45
4.3.1	FOTOGRAFIAS AO AR LIVRE: IMAGENS RGB	45
4.3.2	FOTOGRAFIAS AO AR LIVRE: IMAGENS MATIZ	46
4.4	COMPARAÇÃO DOS RESULTADOS OBTIDOS	47
5	CONCLUSÃO	49
	REFERÊNCIAS.....	51

1 INTRODUÇÃO

Por conta de sua extensão territorial o Brasil proporciona uma ampla gama de atividades econômicas, as quais são divididas em setor terciário, secundário e primário. Uma das mais importantes atividades do setor primário é a produção agrícola. Soja, cana-de-açúcar e milho são as lavouras que tem a maior importância na economia do país. Segundo a última edição do Censo Agropecuário (IBGE, 2017), o valor da produção vegetal do país, em 2017, foi de R\$ 308 bilhões; a soja, que ocupa com folga o topo do ranking, é responsável pelo aporte de R\$ 104 bilhões – ou seja, mais de um terço da produção vegetal total do país.

Entretanto a produção da cultura da soja e sua qualidade podem ser facilmente afetadas por conta de suas pragas e doenças, isto é, se não forem tomadas as devidas medidas de controle fitossanitário. Segundo CORRÊA-FERREIRA; PANIZZI (1999) os percevejos fitófagos (Ordem: Hemiptera) são as pragas mais importantes da soja (*Glycine max* (L.) Merrill) no Brasil. Por se alimentarem dos grãos, afetam seriamente o seu rendimento e a sua qualidade. Ainda de acordo com CORRÊA-FERREIRA; PANIZZI (1999) O percevejo marrom, *Euschistus heros*, espécie rara nos anos 70, é hoje o mais abundante. Nativo da Região Neotropical, tem a soja como seu hospedeiro principal. Adaptado às regiões mais quentes, é mais abundante do Norte do Estado do Paraná ao Centro Oeste Brasileiro.

Segundo STÜRMER (2012) é importante quantificar a densidade populacional de lagartas e de percevejos, para que, com base nos níveis de controle estabelecidos, sejam tomadas decisões adequadas sobre o seu manejo. Existem diversos métodos para amostragem e quantificação de insetos-praga, entretanto são todos métodos manuais, o que acarreta em custos e também torna o método dependente da capacidade cognitiva humana que pode acarretar na imprecisão da quantificação das pragas. Além disso segundo (RODRIGUES, 2013) as projeções de forte aumento da demanda global por alimentos nas próximas décadas passaram também a destacar a importância da ampliação do uso de tecnologia nas lavouras para garantir a contínua elevação da produtividade.

A agricultura de precisão pode ser considerada como um amplo conceito, englobando tecnologias e novos conhecimentos de informática, eletrônica, geoprocessamento entre outros (TSCHIEDEL; FERREIRA, 2002). Segundo GENTIL

& FERREIRA (1999) citado por TSCHIEDEL; FERREIRA (2002) a agricultura de precisão promete grandes benefícios para os usuários deste sistema como:

- Redução do grave problema do risco da atividade agrícola;
- Redução dos custos da produção;
- Tomada de decisão rápida e certa;
- Controle de toda situação, pelo uso da informação;
- Maior produtividade da lavoura;
- Mais tempo livre para o administrador; e
- Melhoria do meio ambiente pelo menor uso de defensivo.

Uma das tecnologias que podem ser empregadas na Agricultura de precisão é o processamento digital de imagens que segundo ARAKI (2016) é uma tecnologia de aplicar algoritmos computacionais para processar uma imagem digital. O uso desta tecnologia tem como objetivo: Melhorar a informação pictorial para interpretação humana e a retirada de informações de uma cena para fins de automação de processos (ARAKI, 2016).

BOAS (2018) afirma que o aprendizado de máquinas é um subcampo da inteligência artificial que busca encontrar e reconhecer padrões nos dados analisados. Ainda de acordo com BOAS (2018) um dos objetivos deste aprendizado é a capacidade de o sistema conseguir generalizar partindo das experiências que foi submetido, sendo capaz de desempenhar com precisão novas tarefas após ter aprendido com um conjunto de dados.

Dentre as ferramentas de aprendizado de máquina existe o método chamado máquina de vetores de suporte (SVM, do inglês: support vector machine) uma técnica extremamente poderosa, usada em processamento digital de imagens. De acordo com LIMA (2014) o SVM são um grupo de métodos de aprendizado de máquina, amplamente utilizado devido a suas atrativas características e desempenho de generalização promissora. Esta técnica tem sido objeto de pesquisa para muitos estudos voltado para o agronegócio, entretanto a detecção de pragas em lavouras, inclusive o percevejo marrom, ainda não é muito explorada.

1.1 OBJETIVO GERAL

Desenvolver um algoritmo de Identificação do Percevejo marrom em imagens embasado na técnica Support Vector Machine (SVM), com o intuito de fomentar a

criação de ferramentas tecnológicas para a detecção do percevejo marrom em lavouras.

1.1.1 Objetivos Específicos

- a) Criação de algoritmo SVM para diferentes cenários;
- b) Avaliar e comparar resultados obtidos com a variação dos parâmetros como fotografias RGB, fotografias Matiz (HSV), distância e condições das tomadas das fotografias utilizadas.
- c) Definir o número mínimo de pixels necessários para a detecção do percevejo.

1.2 JUSTIFICATIVA

Com a grande importância da cultura de soja no Brasil, se faz necessário a exploração de novas técnicas que permitam o controle fitossanitário das lavouras, em especial o percevejo marrom, de tal forma a reduzir o impacto econômico causado aos produtores rurais devido ao uso excessivo de inseticidas e conseqüentemente reduzir o impacto ambiental, que muitas vezes pode resultar no surgimento de novas super espécies de insetos resistentes aos defensivos agrícolas atuais. Além disso deve-se destacar o crescimento mundial e o aumento da demanda por alimento, o que exige que uma mesma área tenha uma produtividade cada vez maior.

Com os resultados obtidos espera-se direcionar o produtor rural de tal forma que a aplicação dos inseticidas seja feita somente nas áreas necessárias, de forma mais rápida e eficaz, acarretando na diminuição do custo de produção e uma otimização na produtividade.

2 REVISÃO DE LITERATURA

2.1 CULTURA DA SOJA

De acordo com a EMBRAPA SOJA (2019) (ibidem) no final da década de 60, dois fatores internos fizeram o Brasil começar a enxergar a soja como um produto comercial, fato que mais tarde influenciaria no cenário mundial de produção do grão. Na época, o trigo era a principal cultura do Sul do Brasil e a soja surgia como uma opção de verão, em sucessão ao trigo. O Brasil também iniciava um esforço para produção de suínos e aves, gerando demanda por farelo de soja. Em 1966, a produção comercial de soja já era uma necessidade estratégica, sendo produzidas cerca de 500 mil toneladas no País (ibidem).

Além disso de acordo com o mesmo autor (ibidem) que a explosão do preço da soja no mercado mundial, em meados de 1970, desperta ainda mais os agricultores e o próprio governo brasileiro. O País se beneficia de uma vantagem competitiva em relação aos outros países produtores: o escoamento da safra brasileira ocorre na entressafra americana, quando os preços atingem as maiores cotações. Desde então, o país passou a investir em tecnologia para adaptação da cultura às condições brasileiras, processo liderado pela Empresa Brasileira de Pesquisa Agropecuária (ibidem).

De acordo com o IBGE (2017) (ibidem) a escalada da produção de soja pode ser observada na comparação com o Censo Agropecuário de 2006. Nesse intervalo, a área colhida aumentou 72%, o número de estabelecimentos aumentou 9% e a quantidade produzida aumentou 123%. Com isto, a soja assumiu a liderança no valor de produção pela primeira vez em um censo agropecuário, desbancando a cana-de-açúcar, tradicionalmente a campeã de valor de produção (ibidem), como é mostrado na figura 1.

FIGURA 1 – RESULTADO DA PRODUÇÃO VEGETAL NACIONAL DE 2017

Lavouras permanentes e temporárias

Valor de produção



FONTE: IBGE, 2017¹

De acordo com o mesmo autor (ibidem) O Brasil é, hoje, o segundo maior produtor mundial de soja. Segundo dados de 2018 da Empresa Brasileira de Pesquisa Agropecuária (Embrapa), a maior parte da soja produzida no Brasil tem como destino a exportação, seja como farelo, óleo ou, principalmente, o grão, gerando U\$ 40,9 bilhões de valor (ibidem).

2.2 PERCEVEJO MARROM

Os percevejos - espécie marrom, segundo CORRÊA-FERREIRA; PANIZZI (1999) apresentam longevidade média que varia de 50 a 120 dias e número de gerações anuais de 3 a 6 dependendo da região. O que garante sua abundância constante pois sua população está sempre se renovando. De acordo com o mesmo autor o percevejo marrom (ibidem) após a colheita da soja, pode se alimentar de carrapicho-de-carneiro, *Acanthospermum hispidum* DC, de girassol, *Helianthus annuus* L., e de guandu, *Cajanus cajan* (L.) Millsp., nesta última planta completa a quarta geração antes de entrar em dormência (diapausa) sob folhas mortas caídas no solo e restos de cultura, onde permanece até a próxima primavera. Esta estratégia

¹ Disponível em: <<https://censos.ibge.gov.br/agro/2017/>>. Acesso em: 15 de novembro de 2019.

permite ao inseto atravessar o período desfavorável (maio a novembro), sem se alimentar, vivendo às custas de energia (lipídios) armazenada antes de entrar em dormência (ibidem).

Devido ao hábito alimentar, os percevejos causam problemas sérios à soja. Seus danos são irreversíveis, a partir de determinados níveis populacionais, afetando diretamente o rendimento e a qualidade das sementes (CORRÊA-FERREIRA; PANIZZI, 1999).

Os percevejos marrons de acordo com GALILEO & HEINRICHS (1978a) citado por NUNES & CORRÊA-FERREIRA (2002) atingem as sementes através da introdução do aparelho bucal nos legumes, tornando-as chochas e enrugadas, afetando, conseqüentemente, a produção e a qualidade dos grãos. De acordo com o mesmo autor podem, ainda, abrir caminho para doenças fúngicas e causar distúrbios fisiológicos, como a retenção foliar da soja.

Segundo NEUMAIER citado por SILVA (2013) retenção foliar é um distúrbio fisiológico na maturação produzido por qualquer fator que interfira, negativamente, no estabelecimento das vagens ou dos grãos ou, ainda, no enchimento desses grãos.

FIGURA 2 - PERCEVEJO MARROM NA VAGEM DE SOJA



FONTE: COTRISJA²

2.3 MÉTODO PANO-DE-BATIDA

² Disponível em: <<http://www.cotrisoja.com.br/soja-resistente/>>. Acesso em: 15 de novembro de 2019.

O Método de Pano-de-Batida consiste de um pano ou plástico branco, cujo comprimento é de 1m e largura adaptável entre as fileiras de soja. O pano enrolado é colocado entre duas fileiras, e então é desenrolado até encostar nos caules das plantas, inclinando-se as mesmo sobre o pano e batendo vigorosamente os insetos caem no pano, de tal forma que podem ser contados e anotados os resultados em uma ficha.

Este método permite que se faça uma amostragem da quantidade de percevejos na cultura da soja. Esta vistoria deve ser executada na lavoura, pelo menos, uma vez por semana nas horas mais frescas do dia, a partir do início do desenvolvimento das vagens até a maturação fisiológica (CORRÊA-FERREIRA; PANIZZI, 1999).

FIGURA 3 - ILUSTRAÇÃO DO MÉTODO PANO-DE-BATIDA



FONTE: EMBRAPA³

2.4 AGRICULTURA DE PRECISÃO

O principal conceito que define a agricultura de precisão, além do uso incansável de tecnologia, é o parcelamento da propriedade rural em pequenas áreas compreendendo cada uma de suas necessidades, ao invés do tratamento tradicional que entende a propriedade rural como uma grande área homogênea.

³ Disponível em: <<https://www.embrapa.br/soja/busca-de-noticias/-/noticia/16589469/emater-pr-e-embrapa-promovem-treinamento-em-boas-praticas-agricolas>>. Acesso em: 16 de novembro de 2019

A solução hoje utilizada é a de focar grandes áreas e entendê-las como homogêneas, levando ao conceito da necessidade média para a aplicação dos insumos - fertilizantes, defensivos, água, etc - o que faz com que, por exemplo, a mesma formulação e/ou quantidade do fertilizante seja utilizada para toda a área, atendendo apenas as necessidades médias e não considerando, desta forma, as necessidades específicas de cada parte do campo (TSCHIEDEL; FERREIRA, 2002).

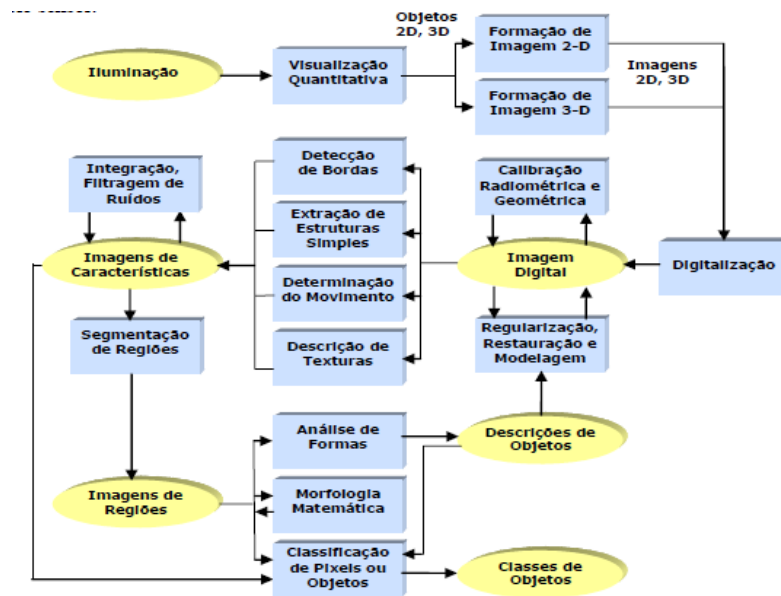
Segundo a EMBRAPA (1997) citado por TSCHIEDEL & FERREIRA (2002) termo agricultura de precisão engloba o uso de tecnologias atuais para o manejo de solo, insumos e culturas, de modo adequado às variações espaciais e temporais em fatores que afetam a produtividade das mesmas.

Segundo CAMPO (2000) citado por TSCHIEDEL & FERREIRA (2002) agricultura de precisão é o conjunto de técnicas e procedimentos que permite conhecer, localizar geograficamente e delimitar áreas de diferente produtividade, através do emprego da informática, programas específicos, sensores, controladores de máquinas e sistema de posicionamento global (GPS).

2.5 PROCESSAMENTO DIGITAL DE IMAGENS

O processamento digital de é composto por um conjunto de tarefas interconectadas. Iniciando-se com a captura da imagem, que corresponde à iluminação que é refletida na superfície dos objetos, isto é, se levarmos em conta a utilização de sensores passíveis. Podendo ser conduzido até a extração de bordas, texturas, vizinhanças e até mesmo na análise e identificação de objetos, tudo isso, de acordo com a necessidade de cada aplicação. A Figura 3 mostra um diagrama genérico para diversas aplicações possíveis no processamento digital de imagens.

FIGURA 4 - EXEMPLO HIERÁRQUICO DE TAREFAS DE PROCESSAMENTO DE IMAGENS



FONTE: ADAPTADO DE QUEIROZ GOMES, 2006

O processamento digital de imagens pode ser dividido em baixo nível e alto nível, de acordo com ARAKI (2016). Os métodos de baixo nível geralmente usam pouco conhecimento sobre o conteúdo ou a semântica das imagens, envolvendo operações como a redução de ruído, o aumento do contraste, a extração de bordas e a compressão de imagens. Segundo o mesmo autor os métodos de alto nível envolvem tarefas como a segmentação das imagens em regiões ou objetos de interesse, descrição desses objetos de modo a reduzi-los a uma forma mais apropriada para representar o conteúdo da imagem e reconhecimento ou classificação desses objetos.

As técnicas de reconhecimento de padrões atuais são divididas basicamente entre aprendizado e classificação, sendo a diferença principal entre elas o fato de que o aprendizado pode ser utilizado em outros conjuntos de dados enquanto a classificação se restringe apenas ao conjunto de dados com o qual foi criado.

Segundo ARAKI (2016) o aprendizado de máquina (machine learning) é uma área da Inteligência Artificial cujo objetivo principal é o desenvolvimento de técnicas computacionais relacionadas ao aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática.

O aprendizado de máquina opera, em geral, com base no esquema descrito a baixo.

FIGURA 5 - ESQUEMA DE APRENDIZADO DE MÁQUINA

	X1	X1	...	<u>Xm</u>	Y
T1	x11	x12	...	xm1	y1
T2	x12	x22	...	xm2	y2
⋮	⋮	⋮	⋮	⋮	⋮
T3	x1n	x2n	...	<u>xmn</u>	<u>yn</u>

FONTE: Os Autores (2019)

Onde T são as instâncias, ou seja, cada uma das amostras fornecidas para a máquina, X são características descritoras e Y o conceito a ser aprendido. Cada técnica de aprendizado de máquina possui seus métodos para a transformação das características X em um conceito Y, os métodos utilizados no SVM serão explicados mais a frente.

Os algoritmos de aprendizado de máquina aprendem, na verdade, através de uma função ou uma hipótese que elaborada a partir dos dados fornecidos para o treinamento. Entretanto segundo ARAKI (2016) esses dados estão sujeitos aos seguintes erros.

- Superadaptação (overfitting): Ocorre quando a hipótese possui baixa capacidade de generalização.
- Subajustamento (underfitting): Ocorre quando a hipótese apresenta uma baixa taxa de acerto.

FIGURA 6 - DIFERENTES SOLUÇÕES PARA AS AMOSTRAS



FONTE: Adaptado MEDIUM, (data desconhecida)⁴

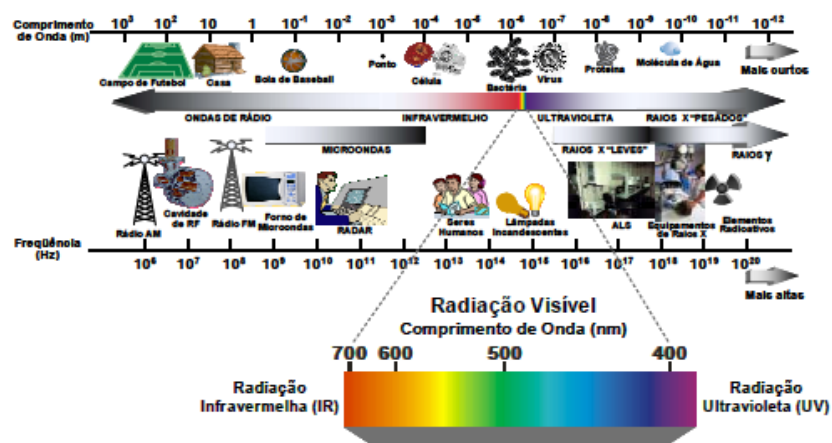
Para estimar o erro de generalização do aprendizado é necessário que se tenha dois conjuntos de amostras, o primeiro que será utilizado para o treinamento em si, e o segundo que será utilizado apenas para teste. Um bom aprendizado é constatado uma vez que são capazes de classificar novos dados. A proporção das imagens de treinamento e teste varia de acordo com o método utilizado e objeto que se deseja classificar, em geral se utiliza uma proporção de 66,6% das imagens para treinamento e 33,3% para teste.

2.6 BANDA MATIZ (HSV)

Segundo QUEIROZ & GOMES (2006) sendo radiação eletromagnética, a luz apresenta um comportamento ondulatório caracterizado por sua frequência (f) e comprimento de onda (λ). A faixa do espectro eletromagnético à qual o sistema visual humano é sensível se estende aproximadamente de 400 a 770 nm e denomina-se luz visível. A figura 6 ilustra as faixas do espectro eletromagnético.

⁴ Disponível em: <<https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76>>. Acesso em: 16 de novembro de 2019.

FIGURA 7 - ESPECTRO ELETROMAGNÉTICO



FONTE: Adaptado QUEIROZ; GOMES, 2006

Os objetos que emitem luz na faixa do visível são percebidos por conta do processo de formação denominado aditivo, que através da soma das cores espectrais refletidas por um objeto torna-o perceptível. Este processo pode ser interpretado como uma fusão variável em proporção de componentes monocromáticas das faixas espectrais associadas às sensações das cores: verde, vermelho e azul, das quais são formadas todas as outras sensações de cores registradas pela visão humana. Baseado neste processo de formação de cores a Comissão Internacional de Iluminação elaborou um modelo cromático denominado RGB (Red, Green e Blue) estabelecendo então as cores primárias como: Vermelho, Verde e Azul.

Além deste sistema de formação de cores, existem muitos outros, um deles é o chamado HSV (Hue, Saturation e Value) que em português significa respectivamente: Matiz, Saturação e Valor. A componente Matiz carrega o valor da cor pura que varia de 0° a 360° , seguido pela Saturação que indica a intensidade da cor pura variando de 0 a 1 e por último a componente Valor que carrega a luminosidade, ou seja, escuro ou claro, podendo variar de 0 a 1.

A obtenção dos valores pode ser facilmente obtida com a utilização das seguintes fórmulas, isto é, para cada valor de pixel (SMITH, 1978).

$$(1) R' = \frac{R}{255}$$

$$(2) G' = \frac{G}{255}$$

$$(3) B' = \frac{B}{255}$$

$$(4) C_{max} = \text{Máx}(R', G', B')$$

$$(5) C_{min} = \text{Min}(R', G', B')$$

$$(6) \Delta = C_{max} - C_{min}$$

$$(7) H = \begin{cases} 60 * \frac{G-B}{C_{max}-C_{min}} + 0, \text{ Se } C_{max} = R \text{ e } G \geq B \\ 60 * \frac{G-B}{C_{max}-C_{min}} + 360, \text{ Se } C_{max} = R \text{ e } G < B \\ 60 * \frac{B-R}{C_{max}-C_{min}} + 360, \text{ Se } C_{max} = G \\ 60 * \frac{R-G}{C_{max}-C_{min}} + 360, \text{ Se } C_{max} = B \end{cases}$$

$$(8) S = \frac{C_{max}}{C_{min}}$$

$$(9) V = C_{max}$$

2.7 MÁQUINA DE VETORES DE SUPORTE (SVM – SUPORT VECTOR MACHINE)

Segundo VIDHYA (2013) citado por LIMA (2014) SVM's desenvolvido por (VAPNIK, 1995), são um grupo de métodos de aprendizado de máquina usados para classificação e regressão, baseia-se no conceito de planos de decisão que definem os limites de decisão, estes planos separam objetos de diferentes classes.

Essa poderosa técnica de aprendizado de máquina está trazendo excelentes resultados para os pesquisadores e cientistas de dados, tornando-se então uma ferramenta importante tanto para o âmbito prático quanto teórico. De acordo com LIMA (2014) estes métodos vêm produzindo excelentes resultados em diversos problemas de classificação, como o reconhecimento de caracteres manuscritos, detecção de faces e imagens, categorização de texto, análises de bio-sequencias.


Matematicamente falando o SVM determina uma separação linear em um espaço de alta dimensão com a utilização de um hiperplano. De acordo com LIMA (2014) uma das principais características do classificador SVM é a robustez em grandes dimensões, possibilitando a sua aplicação em vetores de características de grandes dimensões, por exemplo, contendo imagens.

Considera-se um elemento com dimensão igual a n no espaço de características $\vec{x} = (x_1, \dots, x_n) \in \mathbb{R}_n$, logo pode-se matematicamente definir um hiperplano a partir da equação (1):

$$b_0 + b_1x_1 + \dots + b_px_p = 0 \quad (1)$$

Sendo $b_0 \neq 0$ tem-se um plano afim, que não passa pela origem, capaz de separar duas classes de forma linear. A figura 7 ilustra o princípio básico do SVM, entretanto em um espaço tridimensional, onde os pontos são as amostras com suas respectivas características, visando-se encontrar o melhor plano de separação. Entretanto, em uma aplicação real trabalha-se com um espaço multidimensional, como explicado anteriormente, onde os pontos virão vetores, de onde surge o nome do método, e o plano vira um hiperplano.

FIGURA 8 - PRINCÍPIO SVM E HIPERPLANO



FONTE: Adaptado LIMA, 2014

3 METODOLOGIA

3.1 MATERIAIS

Nesta seção são apresentados os materiais e softwares utilizados neste projeto de conclusão de curso, sendo alguns de propriedade do Laboratório de Entomologia da Pontifícia Universidade Católica do Paraná e outros de propriedade dos autores.

3.1.1 CAMERA

Na figura 8 visualiza-se a câmera fotográfica Sony DSC-HX300. Este equipamento possui uma distância focal de 35 milímetros, possui o número total aproximado de 21,1 Megapixels e um sensor CMOS de 7,82 milímetros.

FIGURA 9 - CÂMERA FOTOGRAFICA SONY DSC-HX300




Fonte: Sony⁵

3.1.2 AMOSTRAS DE PERCEVEJO MARROM

As amostras do percevejo marrom foram fornecidas pelo Laboratório de Entomologia da Pontifícia Universidade Católica do Paraná.

FIGURA 10 - EXEMPLO DAS AMOSTRAS CONTIDAS NO LABORATÓRIO



FONTE: Os Autores (2019)

3.1.3 SOFTWARES

⁵ Disponível em: <<https://www.sony.pt/electronics/camaras-cyber-shot-compactas/dsc-hx300>>. Acesso em: 16 de novembro de 2019.

Os processamentos e o tratamento dos dados, e a geração dos produtos finais foram efetuados com o emprego dos seguintes softwares:

- Google Colab: Plataforma Online de programação, com processamento em nuvem e com um hardware virtual, utilizada visando driblar as limitações de hardware. Também utilizado para compartilhamento em tempo real de processamentos e resultados;
- Pycharm 2019.2: Devido problemas de processamento encontrados no Google Colab, viu-se a necessidade de utilizar outra plataforma de programação em Python. Desta maneira o Pycharm também foi utilizado para realizar processamentos;
- Anaconda 3.0: Gerenciador de Bibliotecas de programação em Python utilizado em conjunto com o Pycharm;
- ImgLab: Utilizado para extração de fotocoordenadas dos objetos de estudo, ou seja, a extração das características das amostras;
- Excel 2010: Utilizado para compilação e análise dos resultados obtidos.

3.1.4 HARDWARE

Os processamentos e tratamento dos dados e a geração dos produtos foram efetuados com a utilização de um hardware com as seguintes especificações fornecidas pela fabricante: Processador Intel® Core™ i5-5200U CPU @ 2.20GHz, com 8 GB de memória ram e sistema operacional Windows de 64 bits.

3.1.5 CENÁRIOS DE TESTE

Para a implementação da base de dados, primeiramente, foram criados cenários, onde o objeto da detecção, o percevejo marrom, foi analisado quanto sua forma e tamanho. Desta maneira foram definidos os procedimentos a serem efetuados no restante do projeto. A criação dos cenários teve como objetivo simular possíveis comportamentos do percevejo marrom. A implementação dos mesmos será decorrida nos itens seguintes.

3.1.5.1 PRIMEIRO CENÁRIO: FOTOGRAFIAS EM LABORATÓRIO

O primeiro cenário localiza-se na Pontifícia Universidade Católica do Paraná, mais especificadamente no Laboratório de Entomologia da instituição, onde foram obtidos os exemplares de percevejos marrons.

Este cenário foi criado com o objetivo de melhor controlar parâmetros como intensidade de luz, distância entre a câmera e o percevejo e variações de posição das amostras. Nesta etapa o percevejo foi fixado em diferentes materiais para a execução dos trabalhos a serem descritos nos itens adiante.

FIGURA 11 - PEPARAÇÃO DO CENÁRIO



FONTE: Os Autores (2019)

Na Figura 11 podemos verificar as preparações para a implementação do primeiro cenário, onde os percevejos foram fixados em algumas superfícies para a realização de testes.

3.1.5.2 SEGUNDO CENÁRIO: FOTOGRAFIAS AO AR LIVRE

Já o segundo cenário foi criado dentro do campus Centro Politécnico da Universidade Federal do Paraná, próximo ao bloco VI, como mostra a figura 11. Sua criação teve como objetivo simular o habitat do percevejo marrom, com condições reais de iluminação.


FIGURA 12 - VISTA ÁREA DE PORÇÃO DO CAMPUS CENTRO POLITÉCNICO



FONTE: Adaptado de UFPR CampusMap⁶

⁶ Disponível em: < <http://www.campusmap.ufpr.br/map/#18/-25.45337/-49.23402>>. Acesso em: 16 de novembro de 2019.

FIGURA 13 - EXEMPLO DE PREPARO DO CENÁRIO AO AR LIVRE



FONTE: Os Autores (2019)

Neste cenário os percevejos foram fixados sob folhas naturais ao ar livre, com o objetivo de simular seu habitat.

3.2 TOMADA DAS FOTOGRAFIAS

As fotografias foram tomadas com cuidados a fim de não serem criados padrões, portanto as imagens possuem uma variação quanto à rotação, inclinação, luminosidade e distância entre a amostra e a câmera, sendo a distância máxima adotada de aproximadamente 1 metro, com intervalos de 20 em 20 cm aproximadamente. Os detalhes das tomadas serão explicitados nos tópicos seguintes.

3.2.1 TOMADA DAS FOTOGRAFIAS EM LABORATÓRIO

Para as primeiras coletas de imagens, o percevejo marrom foi fotografado em planos de fundo diferentes, como papelão, isopor, folhas de papel e folhas vegetais, para que assim fosse possível analisar a influencia do material sob as detecções.

FIGURA 14 - EXEMPLO DE FOTOGRAFIA TOMADA SOB ISOPOR



FONTE: Os Autores (2019)

FIGURA 15 - EXEMPLO DE FOTOGRAFIA TOMADA SOB PAPELÃO



FONTE: Os Autores (2019)

FIGURA 16 - EXEMPLO DE FOTOGRAFIA TOMADA SOB FOLHA DE PAPEL



FONTE: Os Autores (2019)

FIGURA 17 - EXEMPLO DE FOTOGRAFIA TOMADA SOB FOLHA VEGETAL



FONTE: Os Autores (2019)

Uma segunda amostra de imagens foi coletada ainda em laboratório, estas amostras possuem a característica de seu plano de fundo ser constituído apenas por folhas vegetais, a fim de se aproximar de situações reais, onde o percevejo marrom estaria em seu habitat, conforme demonstra a figura 16.

3.2.2 TOMADA DAS FOTOGRAFIAS AO AR LIVRE

Com os objetivos de recriar com mais veracidade as condições do espécime em seu habitat e com condições de iluminação não artificiais, foram tomadas fotografias seguindo a metodologia aplicada sob as imagens de laboratório, variando quando a rotação, inclinação e distância.

FIGURA 18 - EXEMPLO DE FOTOGRAFIA TOMADA AO AR LIVRE



FONTE: Os Autores (2019)


3.3 TRANSFORMAÇÃO DAS IMAGENS

Com o objetivo de obter uma nova solução para o presente projeto de conclusão de curso, todas as imagens coletadas passaram por um processo de transformação RGB para HSV, das quais foram aproveitadas somente a banda H (Matiz). A banda Matiz foi escolhida por distinguir de maneira mais homogênea todos os objetos presentes na imagem.

Outra vantagem de utilizar os dados da banda Matiz é a redução do tamanho das imagens, no sentido de que as imagens RGB apresentam as bandas do vermelho, azul e verde, ou seja, três bandas, enquanto a imagem processada apresenta apenas uma, tornando o processamento mais rápido.


Desta maneira, foi possível realizar testes neste novo conjunto de imagens a fim de possibilitar uma solução diferente para o presente projeto de conclusão de curso. As figuras 19 e 20 mostram como foram os resultados obtidos durante a transformação, com isto percebe-se que os valores de H do percevejo não são homogêneos o suficiente para que fosse possível empregar outras técnicas mais simples, como por exemplo a segmentação, para a sua identificação.

FIGURA 19 – PRIMEIRO EXEMPLO DA TRANSFORMAÇÃO PARA A BANDA MATIZ



FONTE: Os Autores (2019)

FIGURA 20 – SEGUNDO EXEMPLO DA TRANSFORMAÇÃO PARA A BANDA MATIZ



FONTE: Os Autores (2019)

3.4 IMAGENS DE TREINAMENTO

Antes de explicar como foram separadas as imagens para treinamento é importante ressaltar que basicamente o que difere o aprendizado de máquina de uma classificação tradicional é o fato de que o aprendizado de máquinas deve funcionar para um conjunto de imagens diferente das quais foram utilizadas no treinamento.

Além disso com a separação destes grupos é possível estimar o erro de generalização, ou seja, medir a precisão e acurácia da ferramenta. Tendo isto em vista foram criados dois grupos de imagem um para treinamento e outro para teste.

Após a transformação (RGB - HSV) das fotografias foram selecionadas imagens de treinamento para o algoritmo, as imagens foram selecionadas de maneira aleatória para que não houvesse nenhum tipo de interferência nas escolhas. As mesmas amostras de imagens foram utilizadas para o treinamento de imagens RGB e Matiz.

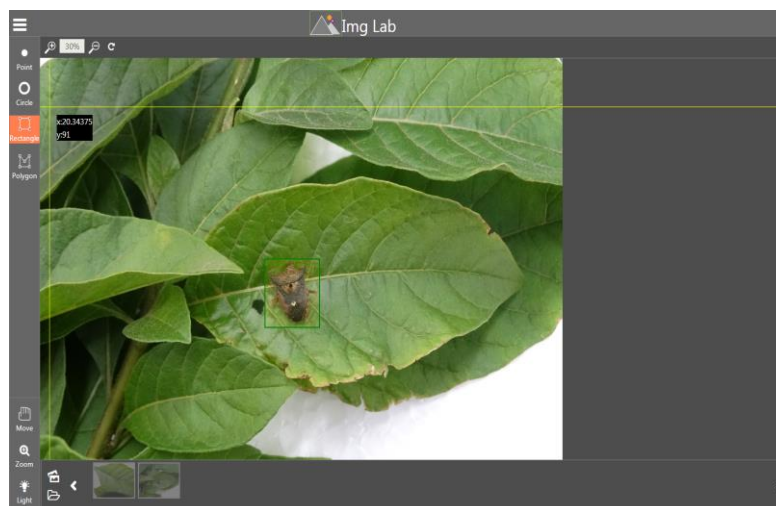
Para o primeiro teste de laboratório, com diversos planos de fundo, foram selecionadas 11 imagens. Já para os demais cenários, foi adotado que de 66% das imagens coletadas seriam separadas para treinamento.

O baixo número de imagens para o presente projeto ocorre por conta de limitações de Hardware. A criação de um banco de dados vasto para o treinamento demanda uma alta utilização de memória RAM, o número de imagens utilizado neste projeto de conclusão de curso é compatível com os limites do Hardware apresentado.

3.5 TREINAMENTO E IMPLEMENTAÇÃO ALGORITMO SVM

Nesta etapa foram definidas, em cada uma das imagens de treinamento, onde se encontravam os percevejos. Para a seleção do objeto nas imagens, com o objetivo de extrair suas fotocoordenadas e fornecer amostras classificadas para o algoritmo, foi utilizado o software ImgLab que proporciona a extração de fotocoordenadas em regiões de interesse e compilar as mesmas posteriormente em um arquivo no formato XML. Ao fazer a leitura do arquivo XML o algoritmo busca nas imagens as informações de pixels correspondentes, ou seja, as características X descritas no item 2.5. Vale lembrar que ao compararmos as características de um percevejo em uma mesma fotografia a representação RGB possui três vezes mais informação do que se comparada a utilização da banda matiz.

FIGURA 21 - EXEMPLO DA SELEÇÃO DO OBJETO EM IMAGENS DE TREINAMENTO



FONTE: Os Autores (2019)

Após a extração das fotocoordenadas, são utilizados os métodos citados no item 2.7 com o objetivo de gerar o algoritmo SVM para a detecção dos percevejos.

Para gerar cada SVM foi utilizado o software Pycharm, juntamente com o gerenciador de bibliotecas de programação Anaconda 3.0 e a biblioteca Dlib, que possui funções pré-determinadas para a implementação do SVM utilizando a linguagem de programação Python.

Para a aplicação dos algoritmos SVM foi utilizada a plataforma Google Colab, onde obtém-se como resultado detecção ou não detecção.

3.6 EXPERIMENTOS E ANÁLISES DE RESULTADO

Após o treinamento e a implementação do algoritmo SVM, o mesmo foi aplicado sob as imagens separadas para teste em cada cenário já citado, em imagens RGB e imagens referentes à banda Matiz.

As análises dos resultados serão feitas avaliando a taxa de identificação do percevejo nas amostras, a taxa da acurácia das imagens onde houve identificação, que seria uma análise em busca de falsos verdadeiros detectados pelo algoritmo, e uma análise visual quanto às condições da tomada da fotografia onde houve a identificação, avaliando principalmente o tamanho em pixel do percevejo identificado.

4 RESULTADOS E DISCUSSÕES

Neste tópico, apresentam-se os resultados alcançados e as devidas discussões. A acurácia apresentada foi calculada através de uma razão entre o total de imagens onde houve a identificação correta, sem falsos verdadeiros, e o total de imagens onde houve a identificação do percevejo. É importante ressaltar que a área mínima obtida em cada um dos tópicos a seguir é inversamente proporcional a distância de tal forma que quanto menor a área menor a distância obtida.

4.1 FOTOGRAFIAS EM LABORATÓRIO COM DIFERENTES PLANOS DE FUNDO

Neste primeiro processamento, o principal objetivo foi avaliar o comportamento do algoritmo em detectar o percevejo em diferentes superfícies, tanto em imagens RGB, quanto em imagens da banda Matiz.

Os resultados serão explicitados nos itens adjacentes.

4.1.1 Imagens RGB

O processamento das imagens RGB resultou em um aproveitamento de 11% de imagens detectadas. Porém, as imagens detectadas apresentaram falsos verdadeiros, contabilizando uma acurácia de 65%.

TABELA 1 - RESULTADOS EM LABORATÓRIO: IMAGENS RGB

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Detecções (%)	Acurácia (%)
176	6,25%	20	22.350	11%	65%

FONTE: Os Autores (2019)

Todas as imagens detectadas tiveram como característica serem imagens de curta distância em relação ao percevejo, cuja a maior distância corresponde a uma área de 22.350 píxels², em contra partida houve acerto em imagens com diferentes rotações, inclinações e em imagens desfocadas.

FIGURA 22 – MAIOR DISTÂNCIA OBTIDA NO ITEM 4.1.1



FONTE: Os Autores (2019)

4.1.2 IMAGENS MATIZ

Os resultados obtidos para as imagens referentes à banda matiz foram piores referente ao aproveitamento, apenas 5%, porem notou-se uma melhora na acurácia visto que apenas uma das imagens caracterizou-se como falso positivo.


Neste processamento também foi possível notar acertos com diferentes rotações e inclinação na tomada das fotografias.

TABELA 2 - RESULTADOS EM LABORATÓRIO: IMAGENS MATIZ

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Detecções (%)	Acurácia (%)
176	6,25%	9	15.376	5%	90%

FONTE: Os Autores (2019)

FIGURA 23 – MAIOR DISTÂNCIA OBTIDA NO ITEM 4.1.2



FONTE: Os Autores (2019)

Ainda referente às imagens da banda Matiz, notou-se que as imagens detectadas em sua maioria eram referentes ao plano de fundo com folhas vegetais, cuja a maior distância obtida corresponde a uma área de 15.376 píxels², um resultado significativamente melhor que com o mesmo grupo de imagens no formato RGB.

4.2 LABORATÓRIO COM FOLHAS VEGETAIS COMO PLANOS DE FUNDO

Neste item serão explicitados os resultados referentes às imagens tomadas no cenário em laboratório tendo como plano de fundo folhas vegetais.

4.2.1 IMAGENS RGB

O processamento resultou numa detecção maior do que a apresentada anteriormente, 26,9% das imagens foram detectadas. Já a acurácia obtida foi de 100%.


TABELA 3 - RESULTADOS COM PLANO DE FUNDO DE FOLHAS VEGETAIS: IMAGENS RGB

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Detecções (%)	Acurácia (%)
81	66%	7	32.041	27%	100%

FONTE: Os Autores (2019)

O resultado mostrou-se positivo visto o baixo número de imagens utilizadas no processo em geral devido às limitações de Hardware encontradas durante os procedimentos, além disso o algoritmo conseguiu diferenciar o percevejo marrom de outro inseto como é mostrado na figura 24. Entretanto analisando a área mínima obtida nas detecções percebe-se que as imagens detectadas ainda representaram apenas as imagens de curta distância.

FIGURA 24 – MAIOR DISTANCIA OBITADA NO ITEM 4.2.1



FONTE: Os Autores (2019)

4.2.2 IMAGENS MATIZ

Já com as imagens Matiz, a detecção obteve um resultado de 62% das imagens, e também com uma acurácia de 100%, sem apresentar falsos verdadeiros.


TABELA 4 - RESULTADOS COM PLANO DE FUNDO DE FOLHAS VEGETAIS: IMAGENS MATIZ

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Detecções (%)	Acurácia (%)
81	66%	16	10.712	62%	100%

FONTE: Os Autores (2019)

Os resultados obtidos foram extremamente satisfatórios visto as condições já citadas em tópicos anteriores. As imagens onde houve identificação também apresentaram melhores resultados quanto a distância da tomada da fotografia, obtendo resultados a uma distância considerada média se analisarmos a área mínima obtida.

FIGURA 25 – MAIOR DISTÂNCIA OBTIDA NO ITEM 4.2.2



FONTE: Os Autores (2019)

4.3 FOTOGRAFIAS TOMADAS AO AR LIVRE

Neste tópico serão apresentados os resultados obtidos quando as fotografias tomadas ao ar livre, para as imagens RGB e as imagens matiz.

4.3.1 FOTOGRAFIAS AO AR LIVRE: IMAGENS RGB

Os testes efetuados ao ar livre apresentaram um percentual de detecção de 42% das imagens tendo 100% de acurácia.

Os acertos nesta etapa, diferentemente das anteriores, ocorreram com uma distância um tanto maior se compararmos com os resultados obtidos no laboratório, os resultados positivos também variam quanto à rotação e inclinação das tomadas das fotografias.

TABELA 5 - RESULTADOS AO AR LIVRE: IMAGENS RGB

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Detecções (%)	Acurácia (%)
75	66%	8	7.392	42%	100%

FONTE: Os Autores (2019)

FIGURA 26 – MAIOR DISTÂNCIA OBTIDA NO ITEM 4.5



FONTE: Os Autores (2019)

4.3.2 FOTOGRAFIAS AO AR LIVRE: IMAGENS MATIZ

Já para as imagens da banda Matiz, o total detectado foi de 37% das imagens, e novamente sem apresentar falsos verdadeiros. Os resultados obtidos ao ar livre foram muito próximos tanto para número de imagens detectadas tanto para a área mínima.

TABELA 6 - RESULTADOS AO AR LIVRE: IMAGENS MATIZ

Imagens Coletadas	Imagens de Treinamento (%)	Imagens Detectadas	Área Mínima (Píxels ²)	Deteccões (%)	Acurácia (%)
75	66%	7	7.296	37%	100%

FONTE: Os Autores (2019)

FIGURA 27 – MAIOR DISTÂNCIA OBTIDA NO ITEM 4.6

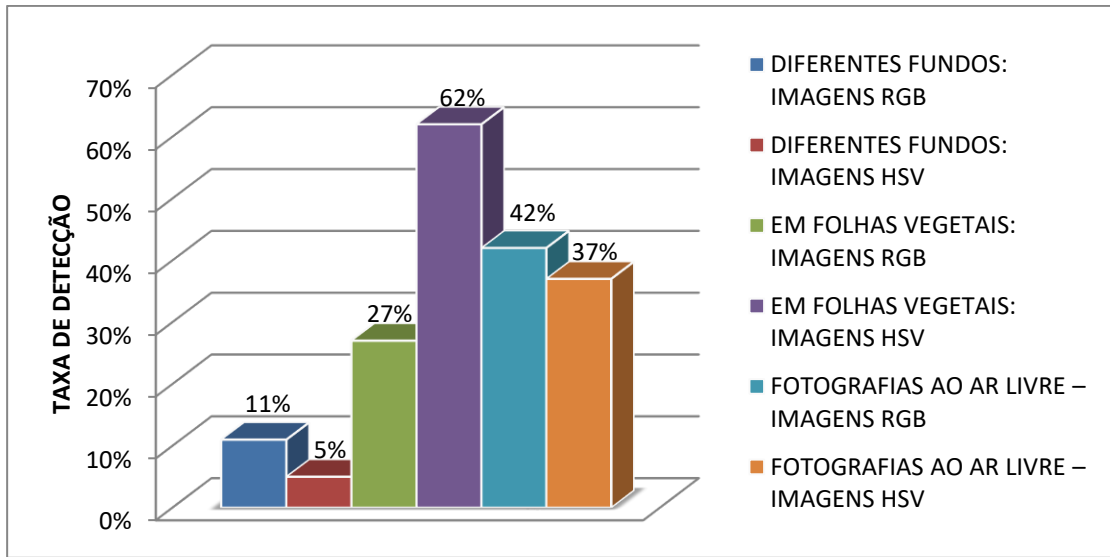


FONTE: Os Autores (2019)

4.4 COMPARAÇÃO DOS RESULTADOS OBTIDOS

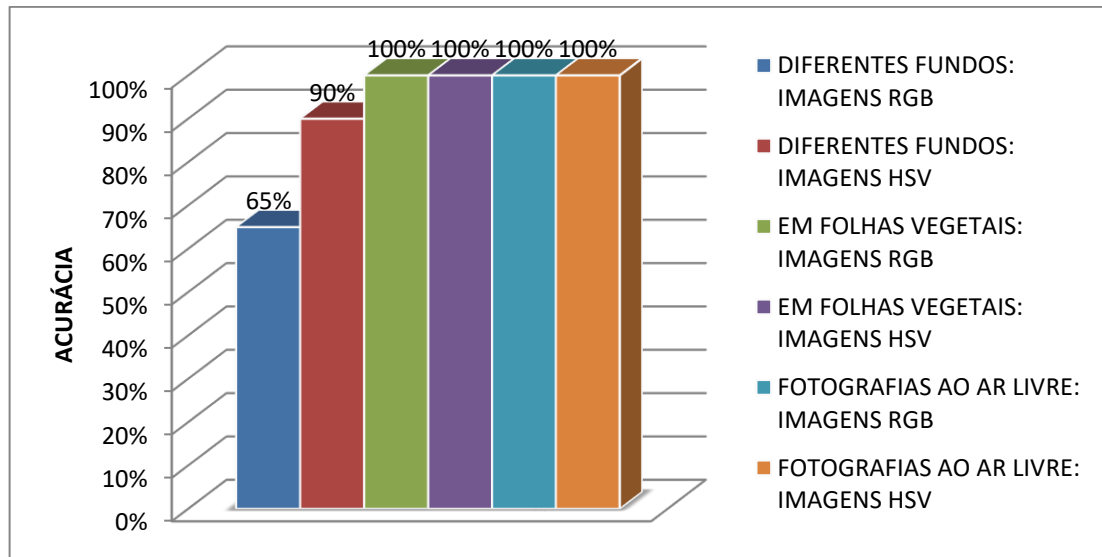
Os resultados dos diferentes cenários e condições de tomada de fotografia serão apresentados graficamente.

GRÁFICO 1 – TAXA DE DETECÇÃO



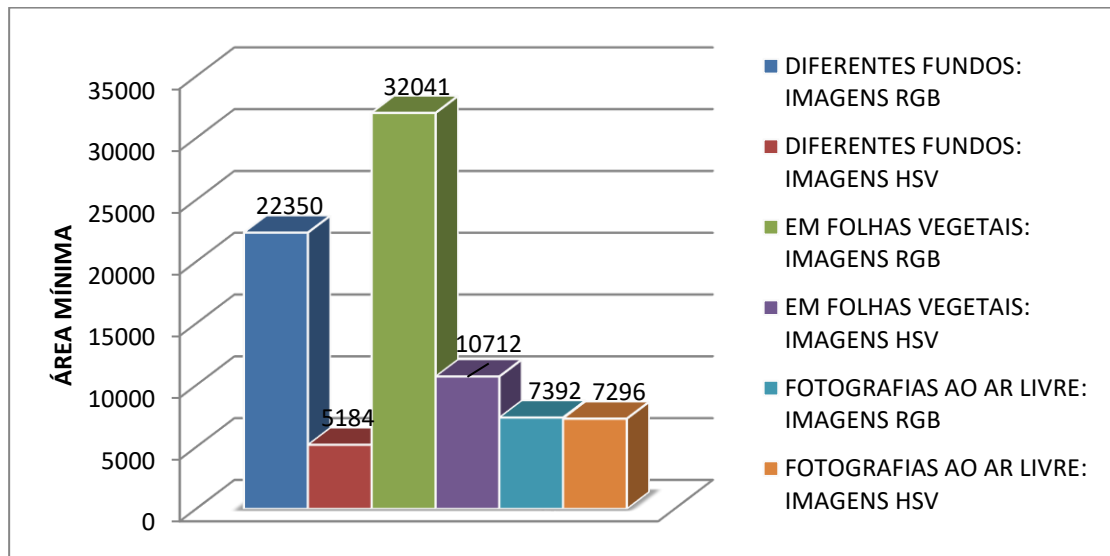
FONTE: Os Autores (2019)

GRÁFICO 2 - ACURÁCIA



FONTE: Os Autores (2019)

GRÁFICO 3 – ÁREA MÍNIMA



FONTE: Os Autores (2019)

Ao analisar numérica e graficamente os resultados nota-se que, no geral, os melhores resultados obtidos foram os referentes às fotografias utilizando a banda Matiz e no geral imagens.

O melhor resultado obtido, tanto para taxa de detecção quanto para área mínima, foram às imagens tomadas em laboratório, utilizando folhas vegetais como plano de fundo e utilizando a banda Matiz, o que, em teoria, expressa as condições ideais para as tomadas e processamentos das fotografias, visto as condições artificiais de iluminação e por ser um ambiente com menos poluição visual se comparado com o cenário ao ar livre desenvolvido neste trabalho.

5 CONCLUSÃO

Para as devidas conclusões deste projeto de conclusão de curso, serão analisados os objetivos apresentados nos itens 1.1 e 1.1.1.

A criação do algoritmo SVM foi efetuada para todos os testes, entretanto a limitação de Hardware influenciou na qualidade das identificações.

Avaliando os resultados obtidos na etapa de identificação do percevejo, foi possível notar que os resultados utilizando as imagens referentes à banda Matiz foram os melhores. Apesar do baixo número de imagens utilizadas nas implementações,

avaliar as condições ideais para as tomadas de fotografias e seus possíveis processamentos foi praticável.

Ao avaliar as fotografias com resultado positivo quanto à presença do percevejo, nota-se que o melhor resultado quanto a área mínima foi de 5.184 pixels², um valor ótimo se considerarmos que com câmeras de alta resolução espacial este valor pode significar uma distância muito boa, de tal maneira que esta tecnologia pode ser embarcada em drones ou até mesmo em maquinários agrícolas.

Já as transformações RGB-HSV mostraram-se uma boa alternativa, não só para a otimização dos processamentos, mas também para as implementações, já que foram obtidos resultados, no geral, melhores que as imagens originais.

Para trabalhos futuros, é interessante avaliar os resultados utilizando outras bandas do espectro. A utilização de câmeras digitais mais modernas também pode influenciar nos resultados. Por fim, executar testes em situações reais de habitat do percevejo marrom, como por exemplo, em lavouras de soja, o que foi impossibilitado neste projeto devido a época de execução, além de trabalhar com uma base de dados muito maior o que não foi possível por conta da capacidade de hardware disponível.

REFERÊNCIAS

ARAKI, Hideo. **Slides de aulas de Processamento digital de imagens I e II**. Curitiba: UFPR, 2016.

BOAS, Vilas et al. **Identificação de pragas na agricultura utilizando APIs de visão computacional**. 2018.

CORREA-FERREIRA, BEATRIZ S.; PANIZZI, ANTÔNIO R. **Percevejos da soja e seu manejo**. Embrapa Soja-Circular Técnica (INFOTECA-E), 1999.

DE QUEIROZ, José Eustáquio Rangel; GOMES, Herman Martins. **Introdução ao processamento digital de imagens**. RITA, v. 13, n. 2, p. 11-42, 2006.

EMBRAPA SOJA, **História da soja**, Disponível em <https://www.embrapa.br/en/soja/cultivos/soja1/historia>. Acesso em: 14 nov. 2019.

IBGE, **Censo agropecuário 2017**, Disponível em <https://censos.ibge.gov.br/agro/2017/>. Acesso em: 14 nov. 2019

IBGE, **Soja lidera valor de produção na agricultura com R\$ 104 bi**, <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/26036-soja-lidera-valor-de-producao-na-agricultura-com-r-104-bi>
Acesso em: 7 nov. 2019

LIMA, Rodrigo Lucio de. **Avaliação do algoritmo SVM na detecção de comportamentos suspeitos em cenas de vídeo**. 2014. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

LUIZ, Cristiane Rodrigues. **A tecnologia no agronegócio**. 2013. Trabalho de Conclusão de Curso. FEMA: Fundação Educacional do Município de Assis – Assis.

NUNES, Maria C.; CORRÊA-FERREIRA, Beatriz S. **Danos causados à soja por adultos de Euschistus heros (Fabricius)(Hemiptera: Pentatomidae), sadios e**

parasitados por Hexacladia smithii Ashmead (Hymenoptera: Encyrtidae). Neotropical Entomology, v. 31, n. 1, p. 109-113, 2002.

SILVA, AJ da; CANTERI, M. G.; SILVA, AL da. **Haste verde e retenção foliar na cultura da soja.** Summa Phytopathologica, v. 39, n. 3, p. 151-156, 2013.

SMITH, Alvy Ray. **Color gamut transform pairs.** ACM Siggraph Computer Graphics, v. 12, n. 3, p. 12-19, 1978.

STÜRMER, Glauber Renato et al. **Eficiência de métodos de amostragem de lagartas e de percevejos na cultura de soja.** Ciência Rural, v. 42, n. 12, p. 2105-2111, 2012.

TSCHIEDEL, Mauro; FERREIRA, Mauro Fernando. **Introdução à agricultura de precisão: conceitos e vantagens.** Ciência Rural, v. 32, n. 1, p. 159-163, 2002.