

CLASSIFICAÇÃO DE DOENÇAS FOLIARES EM CULTURA DE SOJA PELA TRANSFORMADA WAVELET DE HAAR

PRISCILA M. KAI*, FABRÍZZIO ALPHONSUS A. DE M. N. SOARES*, LEANDRO LUÍS G. DE OLIVEIRA*,
GUSTAVO T. LAUREANO*, CRISTIANE B. R. FERREIRA*, THYAGO P. CARVALHO†

*INF - Instituto de Informática - Universidade Federal de Goiás
Câmpus Samambaia (Câmpus II)
Goiânia, Goiás, Brasil

†Instituto Federal de Goiás - Campos Inhumas

Emails: priscilakai@inf.ufg.br, fabrizzio@inf.ufg.br, leandroluis@inf.ufg.br,
gustavo@inf.ufg.br, cristianebrf@gmail.com, thyagopcarvalho@gmail.com

Abstract— Soybean (*Glycine max*), a plant of great economic importance in Brazil and other countries, is the target of a variety of diseases which attack not only leaf part of plant, but also stem, roots and seed itself. Approximately 40 diseases were identified in country, being caused by fungi, bacteria, viruses and nematodes, negatively affecting production, thus limiting crop yield. The objective of this work is to extract texture characteristics of image using the wavelet transform, to analyze regions of soybean leaves affected by pathogens, making the image decomposition, obtaining approximation coefficients. Data that allow classification of the diseases analyzed. The Haar Wavelet Transform was used in feature extraction process and Euclidean distance in classification process. An exploratory database was used, the results were obtained for a proposal effectiveness, whereas adjustments may improve the method presented.

Keywords— Computer Vision, Wavelets, Soybean diseases, Diagnosis by images.

Resumo— A soja (*Glycine max*), planta de grande importância econômica no Brasil e em outros países, é alvo de variadas doenças, que atacam não somente a parte foliar da planta, como também o caule, raízes e a própria semente. Aproximadamente, cerca de 40 doenças já foram identificadas no país, sendo elas causadas por fungos, bactérias, vírus e nematoides, afetando negativamente a produção, limitando então o rendimento da safra. Devido a isto, este artigo tem por objetivo, através da extração de características da textura contida na imagem com a utilização da transformada *wavelet*, efetuar a análise de regiões das folhas de soja afetadas por patógenos, fazendo a decomposição da imagem, obtendo então os coeficientes de aproximação. Dados esses que permitirão realizar a classificação das doenças analisadas. A transformada *wavelet* de Haar foi utilizada no processo de extração de características e a distância Euclidiana no processo de classificação. Uma base de dados exploratória foi utilizada, e os resultados apontam para a efetividade da proposta, ao passo que ajustes poderão aperfeiçoar o método apresentado.

Palavras-chave— Visão Computacional, Wavelets, Doenças de soja, Diagnóstico por imagens.

1 Introdução

Devido ao fator de adaptabilidade da soja aos diferentes tipos de solo e condições climáticas, a planta pode ser considerada de fácil cultivo (Yorinori et al., 1993). Mesmo sofrendo mudanças e melhoramentos com os anos, a soja não deixou de ser alvo de doenças, que com o tempo só aumentam em nível de severidade. Segundo a Embrapa (2014), cerca de 40 doenças já foram identificadas no Brasil. Com isso, a produção de soja tem sido afetada no país, com perdas de produção estimadas de 15% a 20% anualmente.

O controle através do uso de produtos químicos encarece a produção, além de diminuir a qualidade do produto e causar danos ao meio ambiente, além disso, o clima tem grande relevância para a manifestação, severa ou não, de patógenos (Ito, 2013). Assim, para o combate de doenças, a rotação de culturas, consistindo na alternância entre espécies vegetais a cada ano, é uma prática que vem sendo adotada para o controle de patógenos. Entretanto, para algumas doenças, como o oídio e as ferrugens, este método não mostrou eficácia,

necessitando de outras formas para combatê-las (Hoffmann et al., 2004).

A habilidade de diagnosticar doenças em estágio inicial é muito importante para tratar e controlar doenças (Meunkaewjinda et al., 2008). A identificação de doenças geralmente necessita da avaliação de pessoas treinadas para este fim (Embrapa, 2014). Todavia, mesmo profissionais experientes podem ser induzidos ao erro por sintomas similares entre doenças, necessitando então de uma análise mais profunda, como a laboratorial, demandando tempo para exames e custos adicionais.

O processamento digital de imagens tem sido útil para a resolução de problemas como identificação, detecção (Arivazhagan et al., 2013), reconhecimento de padrões e para a classificação (Abdullah et al., 2007), (Barbedo and Godoy, 2015). Essas características têm sido utilizadas por vários pesquisadores, para suporte ao diagnóstico de doenças.

Al Bashish et al. (2010) propuseram um método para detecção de doenças foliares e da haste a partir de texturas. Para segmentação foi uti-

lizado *K-Means*, para extração de características foi analisada a matriz *Color-Co-Occurrence* e para classificação foram utilizadas redes neurais, com acurácia de 93%.

Uma abordagem de mascaramento dos *pixels* verdes presentes na imagem foi utilizada por Arivazhagan et al. (2013), para analisar a textura. Também foi usada a metodologia *Color-Co-Occurrence* com classificação por redes neurais, com utilização do SVM (*Support Vector Machines*), resultando em precisão de 94%. Os autores Rahmani et al. (2015) utilizaram três características principais para classificação de folhas, sendo elas a borda, forma e textura, passando os dados extraídos posteriormente por uma validação cruzada, obtendo melhores resultados de classificação com o algoritmo K-NN para $k = 4$.

Barbedo and Godoy (2015), basea-se na classificação por cor, assim como Abdullah et al. (2007). Foram manuseadas imagens fotografadas em ambiente controlado, aplicando histograma de intensidade da imagem em escala cinza, dividindo o problema em duas classes (classificação de pares), fazendo então uma correlação-cruzada entre histogramas. Esse método obteve resultado satisfatório para apenas duas de nove doenças (com 90% de eficácia para estas).

Para classificar ervas daninhas para um sistema de pulverização automática, Ahmad et al. (2011) aplicou a transformada wavelet de Haar, em imagens nível cinza, para classificar ervas largas de medicinais, utilizando um conjunto dos 200 maiores coeficientes. Para classificação, foi utilizado o K-NN, para $k=2$, na classificação de duas categorias de ervas daninhas. Zhang et al. (2012), utilizou uma abordagem para classificação de espécies de plantas utilizando forma e textura, para classificar 1900 amostras de 32 espécies, com acurácia de 93,8%. Para extração de características da textura foi realizada a decomposição wavelet, até o terceiro nível de decomposição, obtendo então doze coeficientes, dos quais foram calculados o desvio padrão, média e GLCM (*Gray Level Co-occurrence Matrix*). Para a classificação, foi utilizado o SVM (*Support Vector Machine*).

Neste trabalho é apresentada uma abordagem utilizando a transformada de Haar, para suporte na classificação de doenças da soja a partir de imagens. O artigo está estruturado na seguinte forma: na Seção 2 são apresentados os métodos usados no processo de classificação, seguidos pelos experimentos e resultados na Seção 3, finalizando com as Conclusões na Seção 4.

2 Método para Classificação Foliar de Soja

Nesta seção é apresentada a metodologia desenvolvida para reconhecimento das doenças de soja a partir de imagens.

Inicialmente, é necessária a obtenção de imagens foliares afetadas por patógenos, que são pré-processadas com suporte de transformadas *wavelets*. A Figura 1 ilustra o diagrama do processo utilizado no experimento.



Figura 1: Etapas do processo de classificação.

A partir da obtenção de imagens foliares afetadas por patógenos, descritas na subseção 2.1, as amostras são criadas por processos posteriores, referidos na subseção 2.2, seguidos pelo processamento das amostras e a utilização de *wavelets* para a criação das assinaturas de classe, para enfim adquirir a classificação das amostras de teste. Para a construção do método proposto, foi utilizada a plataforma Matlab R2016a[®].

2.1 Construção da base de imagens

Para a construção da base de imagens foliares de cultivares da soja, foi realizada uma coleta na Internet, a partir das doenças de interesse. As imagens escolhidas compreendem folhas (inteiras e parciais) de cinco diferentes patógenos (ferrugem asiática (FA), mancha alva (MA), mancha parda (MP), mancha púrpura (MPU) e olho de rã (OR), sendo estas determinadas doenças selecionadas para fins de estudo) que incidem sobre as folhas da planta. A Figura 2 apresenta um exemplo de uma folha com a doença mancha alva.




Figura 2: Folha de soja afetada pelo patógeno causador da mancha alva.

Foram selecionadas 10 folhas de cada um dos 5 patógenos e extraídas 5 amostras de cada fo-

lha, totalizando 250 amostras, todas de tamanho 64x64 *pixels*. Para fins de experimento, foram utilizadas 80% das amostras para construção dos modelos e 20% restantes para teste de classificação.

Na Figura 3 são retratadas cinco amostras, contendo áreas afetadas por doenças, recortadas manualmente. Ressalta-se que as imagens utilizadas foram produzidas em ambientes com iluminação não controlada, dispositivos com recursos e resoluções diversificadas.




Figura 3: Doenças foliares da soja. (a) Ferrugem Asiática. (b) Mancha Alvo. (c) Mancha Parda. (d) Mancha Púrpura. (e) Olho de rã.

2.2 Pré-processamento

O pré-processamento envolve etapas relacionadas ao tratamento inicial das imagens, incluso o processo de conversão RGB para cinza, com a finalidade de auxiliar processos posteriores como extração de características, envolvendo a decomposição *wavelet* para obtenção dos coeficientes que serão utilizados na classificação dos patógenos.

A partir das imagens de folhas doentes, no modelo RGB de cores, a fim de diminuir a dimensionalidade do problema, as amostras obtidas no processo de construção da base passam pela transformação para escala de cinza.

2.2.1 Decomposição

Neste estudo, a função de análise *wavelet* foi utilizada, sendo capaz de representar uma função em escalas ou níveis diferentes de resolução, permitindo que toda a imagem possa ser representada em uma escala menor, preservando os dados mais significativos (Castilho et al., 2012). Haar, umas das representações mais simples e compactas de funções wavelet foi utilizada no processo, além da vantagem de menor custo computacional.

Após o processo de conversão, em cada amostra é aplicada a transformada *wavelet* no primeiro nível de decomposição, decompondo o sinal de entrada nas partes que a constituem, retornando como resultado quatro variáveis, compostas pelos coeficientes de aproximação, os coeficientes de detalhes horizontais, detalhes verticais e detalhes diagonais. A fim de se obter os coeficientes referentes à imagem de aproximação, compreendendo as baixas frequências, a amostra inicialmente de dimensão 64x64 *pixels*, será analisada e extraída coeficientes a partir da decomposição, resultando na dimensão 32x32.

2.2.2 Ordenação

Posteriormente a etapa de decomposição, envolvendo a etapa de seleção de características, a experimentação é feita com a utilização de uma quantidade diferente de coeficientes, baseados no número de coeficientes de aproximação com maior magnitude, organizados em um vetor composto de 1 linha por n colunas, sendo n número de coeficientes utilizados no primeiro nível de decomposição *wavelet*, inicialmente utilizando todos coeficientes resultantes da imagem 32x32. Uma menor quantidade de coeficientes é utilizada (512, 256, 128, 64, 32 e 16 coeficientes). Essa abordagem foi utilizada para investigar se todos os coeficientes obtidos possuem informação relevante, podendo em sua totalidade influenciar negativamente na classificação dos patógenos.

2.2.3 Normalização

A normalização tem como finalidade fazer com que a variância dos dados seja distribuída de forma mais homogênea. Assim, selecionada as características da imagem decomposta, contendo coeficientes ordenados, é feita a normalização de cada amostra, utilizando os limiares entre 1 e 0, onde cada valor de coeficiente obtido será normalizado após identificar o maior elemento e o menor elemento do vetor de características da amostra.

2.3 Construção de modelos

Para cada quantidade de coeficientes selecionados, é feita a assinatura de classe, que compreende em

calcular as médias de cada coluna dos coeficientes selecionados das amostras de cada doença, obtendo assim no total cinco assinaturas de classe, uma para cada patógeno.

Com a criação das assinaturas de classe, estima-se uma média dos valores de cada característica obtida a partir das amostras. Essas assinaturas serão comparadas posteriormente com os valores das amostras de teste, com o objetivo de verificar a distância entre elas, utilizando como métrica para a classificação.

2.4 Classificação

A classificação das amostras de teste é feita utilizando o classificador de distância mínima, calculando a distância média de cada classe (A_{classe_k}) pela amostra(i) analisada.

Para o cálculo da distância das amostras de teste em relação das assinaturas, a distância euclidiana é dada pela Equação 1:

$$d_k = \sqrt{\sum_i (A_{classe_k} - amostra(i))^2} \quad (1)$$

sendo feita a comparação entre cada amostra de teste e A_{classe_k} , que representa a assinatura de classe de cada patógeno obtido, verificando as distâncias. O resultado com a menor distância determina em qual classe a amostra testada pertence.

Foram utilizadas imagens com diferentes resoluções e condições de iluminação e então obtidas as amostras com um algoritmo de recorte, que selecionava, a partir de cliques, cinco partes de áreas afetadas por patógenos na superfície da folha de soja, com tamanho fixo de 64×64 pixels. No total foram utilizadas 250 amostras, no qual 200 amostras foram utilizadas para formação da base e 50 para testes, considerando para os experimentos a base *wavelet* de Haar, utilizando os coeficientes de aproximação no primeiro nível de decomposição, ordenando os coeficientes por ordem de magnitude, e normalização dos dados e como métrica a distância euclidiana.

2.5 Métricas para avaliação

A partir dos dados obtidos pela matriz de confusão (também chamada matriz de erro), é possível fazer o cálculo da taxa de verdadeiros positivos, falsos positivos, falsos negativos, verdadeiros negativos e precisão dos dados extraídos, possibilitando determinar as medidas estatísticas referentes ao desempenho da classificação, sendo elas a sensibilidade e especificidade. Para calcular a precisão da classificação, utilizou-se a Equação 2.

Já a sensibilidade refere a proporção de dados que foram identificados corretamente, enquanto que a especificidade tem como medida os dados classificados como negativos apropriadamente.

Para o cálculo da sensibilidade e especificidade, foram utilizadas as seguintes Equações 3 e 4,

$$P = VP / (TP + FP), \quad (2)$$

$$S = VP / (TP + FN), \quad (3)$$

$$E = VN / (TN + FP) \quad (4)$$

onde P , S e E são Precisão, Sensibilidade e Especificidade, respectivamente, e VP , VN , FP e FN são Verdadeiros Positivos e Negativos, Falsos Positivos e Negativos, respectivamente.

3 Experimentos e Resultados

Para cada imagem obtida, recortes manuais são realizados, resultando em cinco amostras de cada folha de soja, contendo partes afetadas por doenças. Cada amostra obtida compreendendo em tamanho 64×64 pixels, que após o primeiro nível de decomposição *wavelet* será de 32×32 , com 1024 coeficientes. O processo de decomposição foi repetido até que o número de coeficientes fosse igual a 16.

A Tabela 2 apresenta o resumo dos experimentos realizados. O estudo resultou em sete conjunto de dados, um para cada quantidade de coeficientes selecionados por magnitude (16, 32, 64, 128, 256, 512 e 1024 coeficientes). A partir do cálculo da distância euclidiana de cada amostra de teste com as assinaturas das classes de cinco patógenos foliares da soja, foi obtido uma maior porcentagem de acerto para com os limiares de 512 e 1024 coeficientes, com acerto superior a 50% para duas doenças, na qual, das 10 amostras foliares contendo a doença olho de rã (OR), 70% delas foram classificadas corretamente com 512 coeficientes e em 80% para 1024 coeficientes.

Entretanto, o cálculo de distância entre as classes resultou melhores resultados para 512 coeficientes, com maior valor de verdadeiros positivos, 19 no total, contra 17 com 1024 coeficientes. Para uma quantidade inferior de coeficientes, a doença mancha alvo (MA) foi melhor classificada. A medida do crescimento no total de coeficientes, a classificação foi prejudicada. A doença referente a classe representando a mancha púrpura (MPU) foi o menos classificado corretamente, resultando na classificação como outro patógeno dentre os abordados no estudo.

Na Figura 4 são apresentados os resultados pertinentes ao número de verdadeiros positivos obtidos de todos os coeficientes estudados, é possível observar que para a doença mancha alvo (MA), o número de verdadeiros positivos obtidos entre os limiares de 16 a 32 coeficientes foi superior a 50%. Entretanto, com o acréscimo de coeficientes a classificação é prejudicada, sendo inversamente proporcional ao classificação dos patógenos causadores da mancha parda (MP) e olho de rã (OR),

Tabela 1: Sensibilidade, Especificidade e Precisão da classificação

Classe ideal	16			32			512			1024		
	S	E	P	S	E	P	S	E	P	S	E	P
FA	0,00	0,92	0%	0,70	0,33	28%	0,60	0,59	40%	0,10	0,76	16%
MA	0,60	0,27	27%	0,60	0,43	31%	0,10	0,86	40%	0,00	0,89	0%
MP	0,10	0,91	50%	0,10	1,00	100%	0,40	0,63	31%	0,70	0,48	39%
MPU	0,40	0,28	16%	0,10	0,88	33%	0,10	0,82	20%	0,10	0,73	14%
OR	0,10	1,00	100%	0,10	0,93	50%	0,70	0,67	54%	0,80	0,50	47%

Tabela 2: Matriz de confusão da classificação.

(a) 16 coeficientes

Classes	FA	MA	MP	MPU	OR	FN
FA	0	3	0	7	0	10
MA	0	6	1	3	0	4
MP	0	4	1	5	0	9
MPU	0	6	0	4	0	6
OR	1	3	0	5	1	9
FP	1	10	1	20	0	50

(b) 32 coeficientes

Classes	FA	MA	MP	MPU	OR	FN
FA	7	2	0	1	0	3
MA	3	6	0	0	1	4
MP	5	4	1	0	0	9
MPU	5	4	0	1	0	9
OR	5	3	0	1	1	9
FP	18	13	0	2	1	50

(c) 512 coeficientes

Classes	FA	MA	MP	MPU	OR	FN
FA	6	0	1	1	2	4
MA	2	1	3	2	2	9
MP	3	1	4	1	1	6
MPU	3	0	5	1	1	9
OR	1	2	0	0	7	3
FP	9	3	9	4	6	50

(d) 1024 coeficientes

Classes	FA	MA	MP	MPU	OR	FN
FA	1	1	4	3	1	9
MA	2	0	3	2	3	10
MP	0	0	7	1	2	3
MPU	1	1	4	1	3	9
OR	2	0	0	0	8	2
FP	5	2	11	6	9	50

na qual adquiriram resultados melhores com mais coeficientes.

Os valores resultantes são observados na tabela 2 contendo as matrizes de confusão com seus respectivos limiares selecionados, limitando apenas aos que obtiveram melhores resultados. Também é possível observar a quantidade de falsos negativos (FN) de cada classe e falsos positivos (FP).

Para os demais limiares utilizados no experimento, a classificação obteve resultados inferiores em termos de classificação.

4 Conclusões

Este trabalho foi realizado com o objetivo de classificação de patógenos foliares da soja. Para isto foi utilizada uma abordagem com a transformada *wavelet* de Haar e uma classificação com a utili-

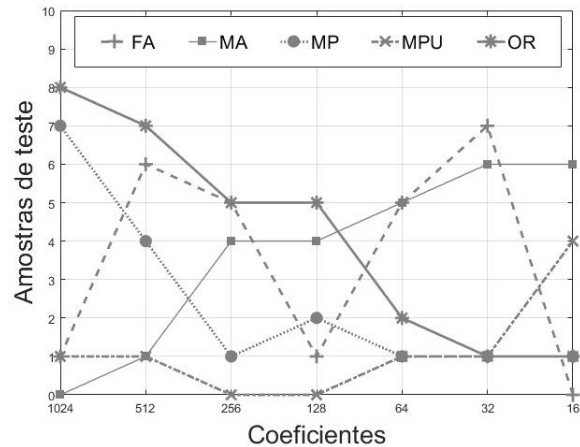


Figura 4: Quantidade de verdadeiros positivos por doença obtidos das amostras de teste a partir do número de coeficientes.

zação da distância euclidiana. Embora tenha sido utilizada uma base de dados pequena, os resultados apresentaram-se promissores, entretanto, alguns problemas precisam ser ajustados.

Como observados nos resultados, alguns tipos de patógenos foram melhor classificados quando utilizados menos coeficientes, como a mancha alva, por exemplo, enquanto outras tiveram melhores resultados quando utilizados mais coeficientes. Isto podem significar características específicas das doenças que seriam afetadas na redução de coeficientes, ou pelo ganho de confusão ao se aumentar o número de coeficientes. Como as imagens foram obtidas pela Internet, as imagens não possuíam um padrão de iluminação, resolução, distâncias, dentre outros, que poderiam também ter comprometido nos resultados.

Finalizando, conclui-se que há uma necessidade de realizar um estudo mais aprofundado a fim de buscar soluções para os problemas apontados, para melhorar a classificação dos patógenos. Todavia, este estudo permitiu verificar o potencial do método proposto, para o problema apresentado.

4.1 Trabalhos futuros

Visando um melhoramento na etapa de extração de características, outras bases *wavelets* podem vir a ser utilizadas, como a transformada de Dau-

bechies e Biorthogonal, que poderiam gerar melhores resultados para classificação, além do uso de redes neurais para classificação. Pretende-se também no futuro colher imagens diretamente da lavoura e assim assegurar a qualidade e padronização de resolução das amostras no estudo.

Referências

- Abdullah, N. E., Rahim, A. A., Hashim, H. and Kamal, M. M. (2007). Classification of rubber tree leaf diseases using multilayer perceptron neural network, *Research and Development, 2007. SCOReD 2007. 5th Student Conference on, IEEE*, pp. 1–6.
- Ahmad, I., Siddiqi, M. H., Fatima, I., Lee, S. and Lee, Y.-K. (2011). Weed classification based on haar wavelet transform via k-nearest neighbor (k-nn) for real-time automatic sprayer control system, *Proceedings of the 5th International Conference on Ubiquitous Information Management and Communication*, ACM, p. 17.
- Al Bashish, D., Braik, M. and Bani-Ahmad, S. (2010). A framework for detection and classification of plant leaf and stem diseases, *Signal and Image Processing (ICSIP), 2010 International Conference on, IEEE*, pp. 113–118.
- Arivazhagan, S., Shebiah, R. N., Ananthi, S. and Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features, *Agricultural Engineering International: CIGR Journal* **15**(1): 211–217.
- Barbedo, J. G. A. and Godoy, C. V. (2015). Automatic classification of soybean diseases based on digital images of leaf symptoms, *SBI AGRO (Oct 2015)*.
- Castilho, J. E., Domingues, M. O., Mendes, O. and Pagamisse, A. (2012). *Introdução ao mundo das Wavelets*, Vol. 62.
- Embrapa (2014). *Tecnologias de Produção de Soja - Região Central do Brasil 2014*, Embrapa Soja.
- Gonzalez, R. C. and Woods, R. E. (2007). *Digital Image Processing*, 3 edn, Prentice Hall.
- Hoffmann, L. L., Reis, E. M., Forcelini, C. A., Pannisson, E., Mendes, C. S. and Casa, R. T. (2004). Efeitos da rotação de cultura, de cultivares e da aplicação de fungicida sobre o rendimento de grãos e doenças foliares em soja, *Fitopatologia Brasileira* **29**(3): 245–251.
- Ito, M. F. (2013). Principais doenças da cultura da soja e manejo integrado, *Nucleus* **10**(3).
- Mallat, S. G. (1989). A theory for multiresolution signal decomposition: the wavelet representation, *IEEE transactions on pattern analysis and machine intelligence* **11**(7): 674–693.
- Martins, M. C., Guerzoni, R. A., Cámara, G. d. S., Mattiazzi, P., Lourenço, S. A. and Amorim, L. (2004). Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja, *Fitopatologia Brasileira* **29**(2): 179–184.
- Meunkaewjinda, A., Kumsawat, P., Attakitmongkol, K. and Srikaew, A. (2008). Grape leaf disease detection from color imagery using hybrid intelligent system, *Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2008. ECTI-CON 2008. 5th International Conference on*, Vol. 1, IEEE, pp. 513–516.
- Rahmani, M. E., Amine, A. and Hamou, M. R. (2015). Plant leaves classification, *ALL-DATA 2015* p. 82.
- Yorinori, J. T., Charchar, M., Nasser, L. C. B., Henning, A. A., Arantes, N. and Souza, P. (1993). Doenças da soja e seu controle, *Cultura da soja nos cerrados*.
- Zhang, H., Yanne, P. and Liang, S. (2012). Plant species classification using leaf shape and texture, *Industrial Control and Electronics Engineering (ICICEE), 2012 International Conference on, IEEE*, pp. 2025–2028.