

A computer vision system for soybean diseases recognition using UAVs: preliminary results

Everton Castelão Tetila¹, Bruno Brandoli Machado², Gercina Gonçalves da Silva³, Hemerson Pistori³

¹Universidade Federal da Grande Dourados, UFGD, Dourados, MS, Brasil

²Universidade Federal de Mato Grosso do Sul, UFMS, Ponta Porã, MS, Brasil

³Universidade Católica Dom Bosco, UCDB, Campo Grande, MS, Brasil

evرتونtetila@ufgd.edu.br, bruno.brandoli@ufms.br, gercina.goncalves@gmail.com, pistori@ucdb.br

Abstract—Soybean has been the main Brazilian agricultural commodity, contributing substantially to the country's trade balance. However, foliar diseases have hindered the high yield of soybean production, leading to depreciation of the final product. This paper proposes a computer vision system to track soybean foliar diseases in the field using images captured by the low cost UAV model DJI Phantom 3. The proposed system is based on the segmentation method SLIC to detect plant leaves in the images and on visual attributes to describe the features of foliar physical properties, such as color, gradient, texture and shape. Our methodology evaluated the performance of six classifiers, using images captured at 2 meters high above the plantation. Experimental results showed that color and texture attributes lead to higher classification rates, achieving the precision of 97,80%. Results indicate that our approach can support experts and farmers to monitor diseases in soybean fields.

Index Terms—soybean foliar diseases, UAVs, aerial images.

I. INTRODUÇÃO

A soja (*Glycine max*) tem sido a principal *commodity* agrícola brasileira, possuindo importante participação econômica na balança comercial do país. O Brasil é o segundo maior produtor mundial de soja, atrás apenas dos EUA. Na safra 2016/2017, o estado de Mato Grosso foi considerado o maior produtor brasileiro do grão (29.952,9 milhões de toneladas), seguido pelo estado do Paraná (18.249,8 milhões de toneladas) e Rio Grande do Sul (16.374,6 milhões de toneladas) [1].

Apesar dos resultados satisfatórios, algumas doenças provocadas por fungos, bactérias, vírus e nematóides tem prejudicado consideravelmente a produção de soja em alguns estados. Na safra 2016/17, o Consórcio Antiferrugem registrou 415 ocorrências de focos da doença ferrugem asiática em diversos estados produtores do Brasil, como Rio Grande do Sul (115 focos), Paraná (87 focos), Mato Grosso do Sul (64 focos), Tocantins (41 focos), Mato Grosso (34 focos), Bahia (32 focos), entre outros [2]. Além disso, doenças como mancha-alvo, míldio e oídio também podem afetar severamente o rendimento da soja. O diagnóstico precoce de doenças é fundamental para a gestão de pesticidas na cultura e, conseqüentemente, pode reduzir os prejuízos econômicos e o impacto ambiental decorrente do uso excessivo de agroquímicos [3].

Embora os danos causados na cultura da soja sejam, em alguns casos, alarmantes, não se indica a aplicação preventiva de produtos químicos, pois a aplicação desnecessária eleva os custos de produção e contribui para o desequilíbrio po-

pulacional de insetos benéficos [4]. O controle das principais doenças da soja deve ser feito com base nos princípios do manejo de doenças da soja [5]. Consiste de tomadas de decisão de controle baseadas no nível de infestação e no estágio de desenvolvimento da soja – informações essas obtidas em inspeções regulares por amostragem em diferentes regiões da lavoura.

Normalmente a detecção da doença é realizada visualmente por um profissional do meio agrônômico, o que pode levar a um diagnóstico impreciso ou incorreto. Bock et al. [6] listam uma série dessas desvantagens. Algumas doenças não têm quaisquer sintomas visíveis associados, ou somente aparecem quando é muito tarde para agir. Nesses casos, algum tipo de análise sofisticada, por meio de microscópios modernos, é geralmente necessária. Em outros casos, os sinais só podem ser detectados em algumas faixas do espectro eletromagnético que não são visíveis aos seres humanos. Uma abordagem comum é o uso de sensores remotos que exploram a captura de imagens multiespectrais e hiperespectrais. A maioria das doenças, no entanto, geram algum tipo de manifestação no espectro visível.

Devido aos altos custos de controle químico e o seu impacto ecológico, um dos objetivos da agricultura de precisão é reduzir e otimizar as aplicações de pesticidas. A detecção e a classificação de várias doenças em estágios iniciais de epidemias permitem uma aplicação mais eficiente de agroquímicos [3]. Contudo, o monitoramento visual de doenças em estágios iniciais no campo é um processo que requer elevado conhecimento técnico, sendo suscetível a falha humana.

Para superar essas questões, há uma crescente motivação ao uso de Veículos Aéreos não Tripulados (VANTs) na agricultura. Segundo a Força Aérea Brasileira (FAB), um VANT é toda aeronave projetada para operar sem piloto a bordo, com carga útil embarcada e não utilizada para fins recreativos. Neste contexto, eles são capazes de sobrevoar uma plantação a poucos metros de distância com câmeras de alta resolução espacial, a fim de capturar imagens ricas em detalhes, o que torna possível a criação de um sistema de visão computacional para identificar diferentes espécies de doenças da cultura de soja. Isso é essencial para a viabilidade deste tipo de aplicação, uma vez que uma grande quantidade de imagens é capturada, sendo necessário analisá-las automaticamente. Além disso, o alto custo de produtos químicos associados a ações de baixo impacto ecológico levam a melhores práticas da agricultura de

precisão. Assim, o uso de VANTs em campos de cultivo tem sido considerado um importante instrumento para identificar manchas de doenças, permitindo que peritos e agricultores tomem melhores decisões gerenciais.

Diante do contexto exposto e da lacuna de pesquisa observada, este artigo propõe um sistema de visão computacional para identificar automaticamente doenças foliares da soja, a partir de imagens aéreas capturadas por um modelo de VANT de baixo custo bastante conhecido no mercado, denominado DJI Phantom 3. Inicialmente, consideramos um passo de segmentação de imagem para detectar as folhas das plantas nas imagens obtidas durante a inspeção de voo. Descrevemos as folhas usando características visuais, incluindo cor, gradiente, textura e forma. Nossa metodologia avalia seis classificadores conhecidos da literatura, utilizando imagens capturadas a 2 metros de altura da plantação. A abordagem proposta utiliza um conjunto de 3.000 imagens, divididas em 6 classes: ferrugem asiática, mancha-alvo, míldio, oídio, solo (solo exposto e palha) e folhas saudáveis - para avaliar a taxa de classificação correta (TCC) do sistema. Os experimentos também compararam as TCC de cada característica visual separadamente para descobrir quais atributos são mais significativos em termos de discriminação na tarefa de reconhecimento de doenças foliares da soja.

Este artigo está organizado da seguinte forma. A Seção II oferece a revisão da literatura. A abordagem proposta para identificar as doenças foliares da soja está descrita na Seção III. A Seção IV relata os materiais e métodos adotados nesta pesquisa. A Seção V mostra os resultados experimentais, seguidos por uma discussão. Finalmente, conclusões e trabalhos futuros são apresentados na Seção VI.

II. REVISÃO DA LITERATURA

Nas últimas décadas muitos sistemas têm sido propostos para a detecção automática de doenças em plantas. No entanto, poucos deles abordam o uso de imagens coletadas por VANTs para a identificação de doenças da soja. Neste contexto, Pires et al. [7] propuseram um método baseado em descritores locais e histogramas de palavras visuais para identificar doenças de soja usando imagens de folhas capturadas por um *scanner* de mesa.

Gui et al. [8] sugerem um novo método adaptado do método *Itti* para detectar doenças da soja com base em regiões salientes. Este método utiliza recursos de baixo níveis de iluminação e cor, combinados com análise multi-escala para determinar mapas de saliência em imagens, utilizando o algoritmo *k-means* e limiar de experiência combinada.

Shrivastava & Hooda [9] apresentam uma aplicação na agricultura para detecção e classificação de duas doenças da soja: mancha marrom e olho de rã. O dispositivo móvel captura a imagem no campo e depois um vetor de atributos de forma é extraído no processamento da imagem que ajuda um classificador k-NN na classificação da doença.

Mohanty et al. [10] descrevem uma arquitetura de rede neural convolucional para problemas de classificação de imagens com um grande número de classes. Usando um conjunto

de dados públicos de 54.306 imagens de folhas de plantas doentes e saudáveis coletadas sob condições controladas, eles treinaram uma rede neural convolucional para identificar 14 espécies de culturas diferentes e 26 doenças.

Pujari et al. [11] analisaram a aparência da doença fúngica oídio em diferentes culturas: uva, manga, pimentão, trigo, feijão e girassol. Eles extraíram características de cor e textura das amostras de oídio e, depois, utilizaram essas características como entrada para dois classificadores: baseado-em-conhecimento e redes neurais artificiais (RNA).

Rumpf et al. [12] propõem um sistema para detectar doenças de plantas utilizando máquina de vetores de suporte baseado em reflectância hiperespectral. A principal contribuição deste trabalho é um procedimento que detecta e classifica, de modo pré-sintomático, as doenças cercospora, ferrugem e oídio da beterraba-sacarina, baseando-se em índices espectrais da vegetação.

Estudos recentes sobre agricultura de precisão, utilizando imagens de sensoriamento remoto obtidas por VANTs e algoritmos de aprendizado de máquina, foram propostos para identificar doenças em cítricos [13], detectar ervas daninhas em trigo [14] e também em milho [15]. Em [16], os autores utilizaram sensoriamento remoto com imagens no espectro do visível e do infravermelho próximo (NIR) para detectar duas doenças de soja, incluindo o nemátodo de cisto e a síndrome da morte súbita. Yuan et al. [17] recentemente usaram VANTs para medir o índice da área foliar da soja.

III. ABORDAGEM PROPOSTA

Nesta seção, apresentamos uma abordagem de visão computacional para identificar doenças foliares da soja através de imagens coletadas pelo VANT Phantom 3. A abordagem proposta adota o algoritmo *Simple Linear Iterative Clustering* (SLIC) para detectar as folhas das plantas nas imagens. O método SLIC emprega o algoritmo *k-means* [18] para a geração de regiões semelhantes, chamadas superpixels. O parâmetro k do algoritmo refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels. Aqui, ajustamos o parâmetro k para melhor segmentar as folhas das plantas de soja.

De acordo com Achanta et al. [19], o algoritmo SLIC agrupa regiões de pixels no espaço 5-D definido por L , a , b (valores da escala CIELAB de cor) e as coordenadas x e y dos pixels. Uma imagem de entrada é segmentada em regiões retangulares, definindo o número k de superpixels com aproximadamente $\frac{N}{k}$ pixels, onde N é o número de pixels da imagem. Cada região compõe um superpixel inicial de dimensões $S \times S$, onde $S = \sqrt{\frac{N}{k}}$. Os centros dos agrupamentos de superpixel $C_k = [l_k, a_k, b_k, x_k, y_k]$ com $k = [1, k]$ são escolhidos, espaçados em uma matriz regular para formar os agrupamentos de tamanho aproximado S^2 . Os centros são movidos para o valor de menor gradiente sobre uma vizinhança de 3×3 pixels, evitando a alocação de centroides nas regiões de borda que tenham pixels ruidosos. Em vez de usar uma norma euclidiana

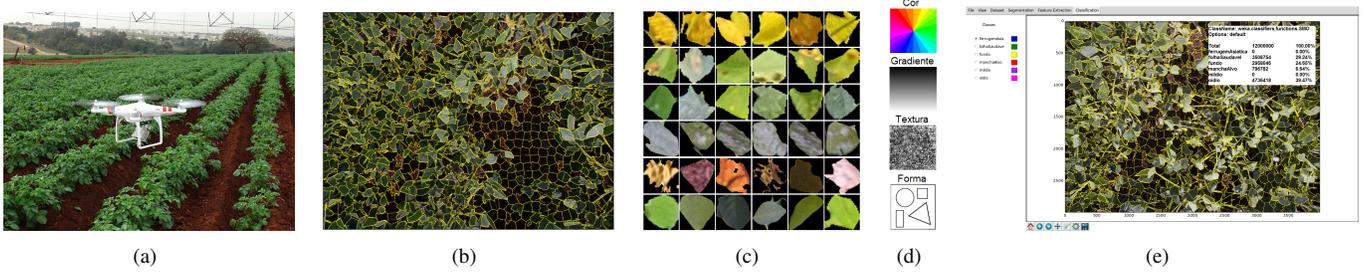


Figura 1. Proposta do sistema de visão computacional para identificar doenças foliares da soja com imagens de VANT.

simples no espaço 5D, uma medida de distância D_s é definida da seguinte forma:

$$d_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (1)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (2)$$

$$D_s = d_{lab} + \frac{m}{s} * d_{xy} \quad (3)$$

onde D_s é a soma da distância d_{lab} (Equação 1) e a distância d_{xy} (Equação 2), normalizada pelo intervalo S . O parâmetro m corresponde ao controle de compactação do superpixel; quanto maior o seu valor, mais compacto é o agrupamento em termos de proximidade espacial. Cada pixel da imagem é associado ao centroide mais próximo de um grupo e, depois de todos os pixels estarem associados a um centroide, um novo centro é calculado com o vetor $Labxy$ de todos os superpixels pertencentes ao grupo. No final do processo, alguns pixels podem estar conectados a um grupo incorretamente, então o algoritmo reforça a conectividade na última etapa, atribuindo os pixels sozinhos aos maiores grupos vizinhos [19].

Um diagrama esquemático do sistema proposto é mostrado na Figura 1. Ela ilustra a metodologia que consiste de cinco etapas: (a) aquisição de imagens, (b) segmentação SLIC, (c) conjunto de imagens, (d) extração de atributos e, finalmente, (e) classificação de doenças foliares. Inicialmente, uma inspeção de voo foi conduzida com o VANT nos campos de soja para capturar imagens da plantação (ver passo (a) na Figura 1). Essas imagens foram segmentadas usando o método SLIC superpixels. Cada segmento de superpixel foi classificado visualmente em uma classe específica: ferrugem asiática, mancha-alvo, míldio, oídio, solo ou amostras de folhas saudáveis. O valor de $k = 2.000$ foi ajustado para dividir a imagem em 2.000 segmentos de superpixels (Figura 1 (b)). Este valor corresponde ao tamanho aproximado da segmentação de uma folha de soja.

Após a segmentação da imagem com o método SLIC, os segmentos foliares pertencentes à classe foram visualmente analisados por um especialista para compor um conjunto de imagens de superpixels para treinamento e teste do sistema, ver etapa (c) da Figura 1. Neste caso, um perito ou um agrônomo foi responsável pela avaliação da representatividade da amostra para a análise estatística. Subsequentemente, as imagens foram descritas como características baseadas na cor, gradiente, textura e forma (ver passo (d) da Figura 1) através de vetores de atributos extraídos das imagens de superpixels.

A etapa final mostra uma imagem de teste avaliada pelo nosso sistema de visão computacional (ver passo (e) da Figura 1). O resultado da taxa de classificação calculada para cada uma das doenças é mostrado na captura de tela da nossa ferramenta.

IV. MATERIAIS E MÉTODOS

As próximas seções cobrem os materiais e métodos adotados neste artigo.

A. Delineamento Experimental

As imagens das plantas de soja foram capturadas a 2 metros de altura com o VANT Phantom 3. Neste caso, nós escolhemos dois metros porque valores menores causam o deslocamento das folhas devido ao vento gerado pelas pás dos rotores. Em contrapartida, para valores mais altos o tamanho das folhas nas imagens é gradativamente reduzido e, conseqüentemente, a resolução da imagem diminui. A Figura 2 mostra diferentes alturas testadas, no caso, 1, 2, 4, 8 e 16 metros.

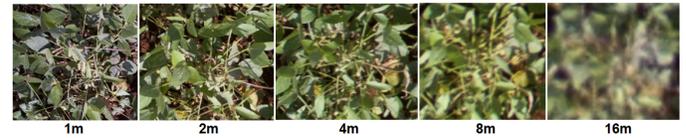


Figura 2. Planta da soja com a presença da doença do oídio capturada pelo VANT em diferentes alturas.

Para tanto, as imagens foram capturadas a partir de um campo experimental de soja, mostrado na Figura 3. A área agrícola é situada na fazenda Bom Princípio, localizada no município de Dourados-MS, com coordenadas geográficas $22^{\circ} 6' 22.77''$ latitude Sul e $54^{\circ} 15' 20.05''$ longitude Oeste. Foram coletadas 100 imagens aéreas durante a safra Set/2016–Fev/2017. A fim de identificar as folhas das plantas nas imagens, cada imagem foi segmentada por meio do método baseado em superpixel, de acordo com o parâmetro k que melhor ajusta a detecção das folhas na planta. Para os nossos experimentos, os melhores parâmetros k foram encontrados empiricamente com o valor de 2.000 superpixels para segmentar as folhas das plantas de soja. Como resultado, 3.000 imagens de superpixels, sendo 500 imagens para cada classe, foram distribuídas entre as seis classes de identificação de doenças da soja. As classes, neste caso, correspondem às doenças: ferrugem asiática, mancha-alvo, míldio, oídio, solo e folhas sem doença.



Figura 3. Visão aérea da área experimental utilizada para o plantio da cultura de soja.

Com apoio de um especialista da área agrônômica, cada imagem foi anotada, construindo assim, uma coleção de referências de superpixels para o conjunto de imagens (veja a Figura 4). As imagens no formato .DNG foram capturadas utilizando o VANT modelo DJI Phantom 3 Professional, equipado com um sensor Sony EXMOR de 1/2,3 polegadas e 12,3 megapixels de resolução. As imagens foram capturadas a 2 metros de altura da plantação sobre os alvos de interesse, usando um ângulo de 90° da câmera em relação ao solo. Os alvos, neste caso, correspondem ao estrato superior da planta (folhas) que carregam as informações de doenças da soja.

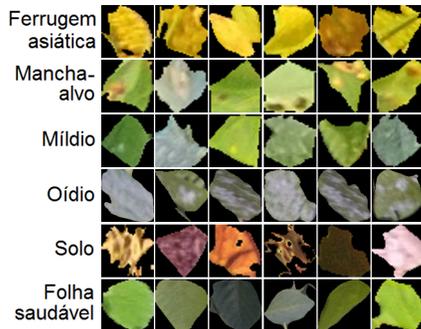


Figura 4. Exemplos de imagens de superpixels do nosso conjunto de imagens, divididos em doenças, solo e folha saudável.

B. Extração de Atributos e Classificação

Extração ou descrição de atributos é um passo importante nos sistemas de classificação, visto que esta etapa é capaz de reduzir a informação dos padrões de conteúdo visual e representá-los em um vetor de características. Existem vários atributos visuais que descrevem as propriedades físicas das imagens, que dependem principalmente da cor, gradiente, textura e forma. Embora o sistema visual humano possa facilmente discriminar imagens, a descrição das características baseia-se nas propriedades físicas das superfícies dos objetos, ou seja, como elas refletem os diferentes valores de comprimento de onda. Os atributos de textura se concentram em descrever imagens como padrões repetitivos que podem variar de acordo

com o tamanho, o que produz diferentes sensações táteis associadas à aspereza, grosseria e regularidade. Forma descreve imagens dependendo do contorno dos objetos, enquanto as características de gradiente são baseadas nas derivadas em diferentes direções da imagem. Em nosso sistema de classificação de imagens, implementamos e usamos como atributos os seguintes métodos: cor (estatísticas de cores [20]), gradiente (histograma de gradientes orientados [21]), textura (matriz de co-ocorrência de nível de cinza [22] e padrões binários locais [23]) e forma (momentos de Hu e momentos centrais [24]).

Para a classificação de imagens, os algoritmos de aprendizagem de máquina usam as imagens descritas para identificar e classificar de acordo com os padrões visuais. Aqui, empregamos modelos de aprendizagem supervisionados com conjuntos de treinamento e teste divididos de acordo com a validação cruzada de dez dobras. Nós comparamos classificadores bem conhecidos, incluindo SMO [25], *Adaboost* [26], árvores de decisão usando o algoritmo J48 [27] e *Random Forest* [28], *k*-vizinhos mais próximos (*k*-NN) [29] e *Naive Bayes* [30], a fim de avaliar estatisticamente o potencial da proposta de reconhecimento foliar nos campos de soja.

V. RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Nesta seção, descrevemos os experimentos e os resultados obtidos pela abordagem proposta. Na tarefa de classificação, submetemos aos modelos de aprendizado de máquina as imagens capturadas. Quatro métricas foram utilizadas para avaliar o desempenho dos classificadores: taxa de classificação correta (TCC), medida-F, área ROC e tempo médio para construir o modelo de classificação. Para treinamento e teste dos classificadores, foi utilizada a validação cruzada de 10 dobras estratificada. Neste esquema, as imagens do conjunto de dados são divididas em 10 dobras, garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para testar, enquanto as dobras restantes são usadas para treinar o classificador. O processo é repetido 10 vezes usando cada dobra exatamente uma única vez para o teste. Finalmente, a taxa de classificação correta é dada pela média das 10 rodadas. Para cada algoritmo testado, foram calculados os desempenhos médios das métricas ajustadas para problemas com mais de duas classes.

Para verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho, nós utilizamos o teste de hipóteses ANOVA no *RStudio*, com cada bloco correspondendo a uma classe do problema. Os valores-*p* encontrados para cada métrica e o nível de significância requerido foram relatados para descartar a hipótese nula. Em seguida, os dados foram analisados a partir de uma linha estatística descritiva no diagrama *boxplot*.

A. Avaliação de Classificação

A Figura 5 mostra os resultados de TCC obtidos por seis classificadores bem conhecidos da literatura, considerando os valores da Tabela I. É possível observar que não existe diferença significativa de desempenho de TCC entre

os classificadores SMO e *Random Forest*. Este resultado foi confirmado pelo teste de *Tukey* ($P < 0,05$). Neste critério de desempenho, o classificador SMO obteve maior TCC, seguido pelos classificadores *Random Forest*, J48, k-NN, *Naive Bayes* e *Adaboost*. A Tabela I também mostra o tempo médio para construir o modelo de classificação. Conforme a tabela, o classificador k-NN obteve menor tempo de processamento, seguido pelos classificadores *Adaboost*, *Naive Bayes*, SMO, J48 e *Random Forest*.

Tabela I
MÉTRICAS DE DESEMPENHO UTILIZADAS PARA AVALIAR O SISTEMA DE VISÃO COMPUTACIONAL PROPOSTO.

Classificador	TCC (%)	Medida-F (%)	Área ROC (%)	Tempo (s)
SMO	97,80	97,80	99,50	0,62
<i>RandomForest</i>	97,76	97,80	99,90	4,47
J48	94,93	94,90	97,30	1,78
<i>NaiveBayes</i>	51,16	48,50	90,50	0,20
k-NN	88,03	88,00	92,80	0,00
<i>AdaBoost</i>	32,96	18,30	72,10	0,19

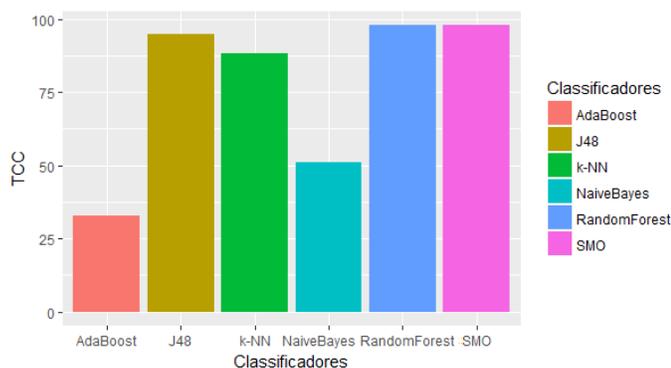


Figura 5. TCC obtido por diferentes classificadores, utilizando extratores de atributos combinados baseados em cor, gradiente, textura e forma.

A Figura 6 apresenta o desempenho de cada classificador para a métrica TCC, com o valor da mediana em destaque no diagrama *boxplot*. O diagrama apresenta ainda o intervalo da variação do desempenho obtido por cada classificador. De acordo com a figura, o classificador SMO apresentou a melhor TCC, possuindo maior valor para a mediana e dispersão de dados na melhor faixa de valores para a TCC.

A Figura 7 apresenta a matriz de confusão do classificador SMO - que obteve o melhor resultado para a TCC. De acordo com a figura, as classes oídio/mancha-alvo e mildio/folha saudável obtiveram maior número de instâncias classificadas incorretamente, devido ao grau de semelhança existente entre essas classes.

B. Avaliação de Extratores de Atributos

Outro objetivo do experimento foi avaliar o desempenho de cada característica visual que descreve as propriedades físicas da folha. Para este propósito, os atributos baseados em cor, gradiente, textura e forma foram comparados individualmente em termos de TCC calculados pelo classificador SMO, como mostra a Figura 8. Os resultados deste experimento demonstram

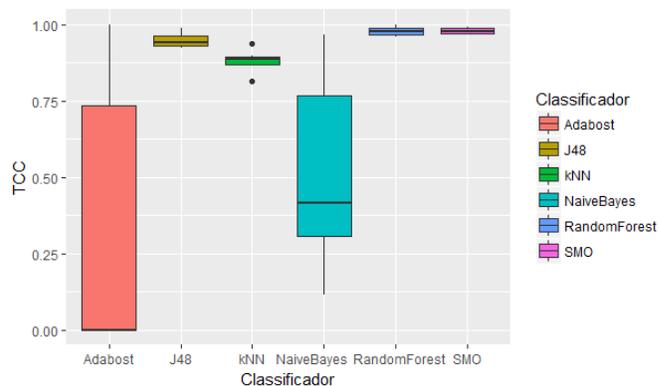


Figura 6. Diagrama *boxplot* comparando o desempenho entre os classificadores para a métrica TCC.

	ferrugem	saudável	fundo	mancha-alvo	mildio	oídio
ferrugem	495	0	3	2	0	0
saudável	0	489	0	0	10	1
fundo	2	0	496	0	0	2
mancha-alvo	3	1	0	488	0	8
mildio	0	12	0	1	483	4
oídio	0	0	2	11	4	483

Figura 7. Matriz de confusão obtida pelo classificador SMO com a TCC para cada classe investigada.

que para o classificador avaliado, os atributos cor (97,53%) e textura (68,96%) são mais significativos em termos de discriminação quando comparados aos atributos de gradiente (46,16%) e forma (25,13%) na tarefa de reconhecimento de doenças foliares da soja.

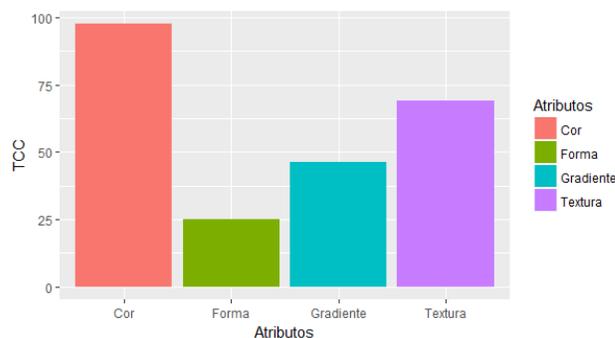


Figura 8. TCC obtido pelo classificador SMO, utilizando cada extrator de atributo separado, baseado em cor, gradiente, textura e forma.

O atributo cor é mais significativo que os demais atributos porque as manchas de doenças geralmente apresentam diferentes colorações na folha. Os primeiros sintomas da ferrugem asiática são caracterizados por pequenos pontos de coloração esverdeada a cinza-esverdeada, mais escuros do que o tecido sadio da folha. As lesões da mancha-alvo se iniciam por pontuações pardas, com halo amarelado, evoluindo

para grandes manchas circulares de coloração castanho-clara a castanho-escuro. Os sintomas iniciais do míldio são manchas verde-claras que evoluem para a cor amarela na parte superior da folha. Já a doença oídio apresenta uma fina cobertura esbranquiçada nas folhas em decorrência da coloração branca do fungo [31].

VI. CONCLUSÃO

Neste artigo foi proposta uma nova abordagem baseada no método de segmentação SLIC para identificar doenças foliares da soja utilizando VANTs. Consideramos um passo de segmentação de imagem para detectar as folhas das plantas nas imagens tomadas com voos de um VANT modelo Phantom. Em seguida, foi realizada a etapa de extração de características usando descritores visuais, incluindo cor, gradiente, textura e forma. Na etapa de classificação da nossa abordagem, comparamos seis classificadores bem conhecidos na literatura. A taxa de classificação correta confirmou que a nossa abordagem obteve a precisão de 97,80% na identificação da doença foliar, utilizando o classificador SMO em imagens capturadas a 2 metros de altura. Os resultados experimentais também indicaram que os atributos de cor e textura levam a maiores taxas de classificação. Como parte de trabalhos futuros, pretendemos realizar novos experimentos com câmeras multiespectrais e de maior resolução. Também consideramos comparar a nossa abordagem com outras abordagens de aprendizagem.

REFERÊNCIAS

- [1] C. N. de Abastecimento (CONAB), "Acompanhamento da safra brasileira grãos, v.4 - safra 2016/17 - n.6 - sexto levantamento (in portuguese)," Brasília, DF, Brasil, pp. 1–176, 2017. [Online]. Available: http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_03_14_15_28_33_boletim_graos_marco_2017bx.pdf
- [2] E. B. de Pesquisa Agropecuária (EMBRAPA), "Consórcio antiferrugem (safra 2016/2017) (in portuguese)," Brasília, DF, Brasil, 2016. [Online]. Available: <https://www.embrapa.br/soja/ferrugem/consorcioantiferrugem>
- [3] C. Hillnhuetter and A.-K. Mahlein, "Early detection and localisation of sugar beet diseases: new approaches," *Gesunde Pflanzen*, vol. 60, no. 4, pp. 143–149, 2008.
- [4] E. B. de Pesquisa Agropecuária (EMBRAPA), "Níveis de desfolha tolerados na cultura da soja sem a ocorrência de prejuízos à produtividade (in portuguese)," Londrina, PR, Brasil, 2010. [Online]. Available: <http://www.cnpso.embrapa.br/download/CT79VE.pdf>
- [5] A. A. Henning, "Manejo de doenças da soja (glycine max l. merrill) (in portuguese)," *Informativo ABRATES*, vol. 19, no. 3, p. 4, 2009. [Online]. Available: <http://ainfo.cnpqia.embrapa.br/digital/bitstream/item/96109/1/Manejo-de-doencas-da-soja-Glycine-max-L.-Merrill.pdf>
- [6] C. Bock, G. Poole, P. Parker, and T. Gottwald, "Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging," *Critical Reviews in Plant Sciences*, vol. 29, no. 2, pp. 59–107, 2010.
- [7] R. D. L. Pires, D. N. Gonçalves, J. P. M. Oruê, W. E. S. Kanashiro, J. F. Rodrigues, B. B. Machado, and W. N. Gonçalves, "Local descriptors for soybean disease recognition," *Computers and Electronics in Agriculture*, vol. 125, pp. 48–55, 2016.
- [8] Q. Z. Jiangsheng Gui, Li Hao and X. Bao, "A new method for soybean leaf disease detection based on modified salient regions," *International Journal of Multimedia and Ubiquitous Engineering*, vol. 10, pp. 45–52, 2015.
- [9] D. S. H. Sourabh Shrivastava, "Automatic brown spot and frog eye detection from the image captured in the field," *American Journal of Intelligent Systems*, vol. 4, no. 4, pp. 131–134, 2014.
- [10] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *CoRR*, vol. abs/1604.03169, 2016. [Online]. Available: <http://arxiv.org/abs/1604.03169>
- [11] J. D. Pujari, *Recognition and classification of Produce affected by identically looking Powdery Mildew disease*, Y. Rajesh, Ed. De Gruyter Open, 2014. [Online]. Available: <https://doaj.org/article/ef63bd9fffc34d42af2146c82c9127da>
- [12] T. Rumpf, A.-K. Mahlein, U. Steiner, E.-C. Oerke, H.-W. Dehne, and L. Plümer, "Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance," *Computers and Electronics in Agriculture*, vol. 74, no. 1, pp. 91 – 99, 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0168169910001262>
- [13] F. Garcia-Ruiz, S. Sankaran, J. M. Maja, W. S. Lee, J. Rasmussen, and R. Ehsani, "Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees," *Comput. Electron. Agric.*, vol. 91, pp. 106–115, 2013.
- [14] J. Torres-Sánchez, J. Peña, A. de Castro, and F. López-Granados, "Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images UAV," *Computers and Electronics in Agriculture*, vol. 103, pp. 104–113, 2014.
- [15] J. M. Peña, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, and F. López-Granados, "Quantifying efficacy and limits of unmanned aerial vehicle (uav) technology for weed seedling detection as affected by sensor resolution," *Sensors*, vol. 15, no. 3, pp. 5609–5626, 2015.
- [16] S. G. Bajwa, J. C. Rupe, and J. Mason, "Soybean disease monitoring with leaf reflectance," *Remote Sensing*, vol. 9, no. 2, pp. 127–133, 2017.
- [17] H. Yuan, G. Yang, C. Li, Y. Wang, J. Liu, H. Yu, H. Feng, B. Xu, X. Zhao, and X. Yang, "Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of rf, ann, and svm regression models," *Remote Sensing*, vol. 9, no. 4, pp. 309–315, 2017.
- [18] J. A. Hartigan and M. A. Wong, "A k-means clustering algorithm," *JSTOR: Applied Statistics*, vol. 28, no. 1, pp. 100–108, 1979.
- [19] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, "Slic superpixels compared to state-of-the-art superpixel methods," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 11, pp. 2274–2282, 2012. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2012.120>
- [20] M. J. Swain and D. H. Ballard, "Color indexing," *International Journal of Computer Vision*, vol. 7, no. 1, pp. 11–32, 1991. [Online]. Available: <http://dx.doi.org/10.1007/BF00130487>
- [21] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 1. IEEE, 2005, pp. 886–893.
- [22] R. M. Haralick, "Statistical and structural approaches to texture," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [23] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 7, pp. 971–987, 2002. [Online]. Available: <http://dx.doi.org/10.1109/TPAMI.2002.1017623>
- [24] M. K. Hu, "Visual Pattern Recognition by Moment Invariants," *IRE Transactions on Information Theory*, vol. 8, pp. 179–187, 1962.
- [25] J. C. Platt, "Advances in kernel methods," B. Schölkopf, C. J. C. Burges, and A. J. Smola, Eds. Cambridge, MA, USA: MIT Press, 1999, ch. Fast Training of Support Vector Machines Using Sequential Minimal Optimization, pp. 185–208. [Online]. Available: <http://dl.acm.org/citation.cfm?id=299094.299105>
- [26] B. Kégl, "The return of adaboost.mh: multi-class hamming trees," *CoRR*, vol. abs/1312.6086, 2013. [Online]. Available: <http://arxiv.org/abs/1312.6086>
- [27] J. R. Quinlan, "Induction of decision trees," *Mach. Learn.*, vol. 1, no. 1, pp. 81–106, Mar. 1986. [Online]. Available: <http://dx.doi.org/10.1023/A:1022643204877>
- [28] T. K. Ho, "Random decision forests," in *Proceedings of the Third International Conference on Document Analysis and Recognition*, ser. ICDAR '95. Washington, DC, USA: IEEE Computer Society, 1995, pp. 278–285. [Online]. Available: <http://dl.acm.org/citation.cfm?id=844379.844681>
- [29] N. S. Altman, "An introduction to kernel and nearest-neighbor non-parametric regression," *The American Statistician*, vol. 46, no. 3, pp. 175–185, 1992.
- [30] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 2nd ed. Pearson Education, 2003.
- [31] E. B. de Pesquisa Agropecuária (EMBRAPA), "Manual de identificação de doenças de soja - 5ª edição (in portuguese)," 2014.