

Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros



**Empresa Brasileira de Pesquisa Agropecuária
Embrapa Mandioca e Fruticultura
Ministério da Agricultura, Pecuária e Abastecimento**

**BOLETIM DE PESQUISA
E DESENVOLVIMENTO
137**

Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros

Romulo da Silva Carvalho
José Eduardo Borges de Carvalho

Embrapa Mandioca e Fruticultura
Cruz das Almas, BA
2022

Exemplares desta publicação podem ser adquiridos na:

Embrapa Mandioca e Fruticultura
Rua Embrapa, s/nº, Caixa Postal 07
44380-000, Cruz das Almas, Bahia
Fone: 75 3312-8048
www.embrapa.br
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações
da Embrapa Mandioca e Fruticultura

Presidente
Eduardo Chumbinho de Andrade

Secretária-Executiva
Maria da Conceição Pereira da Silva

Membros
*Ana Lúcia Borges, Áurea Fabiana Apolinário de
Albuquerque Gerum, Cinara Fernanda Garcia
Morales, Harllen Sandro Alves Silva, Herminio
Souza Rocha, Jailson Lopes Cruz, José
Eduardo Borges de Carvalho, Paulo Ernesto
Meissner Filho, Tatiana Góes Junghans*

Supervisão editorial
Eduardo Chumbinho de Andrade

Revisão de texto
Alessandra Angelo

Normalização bibliográfica
Sônia Maria Sobral Cordeiro

Projeto gráfico da coleção
Carlos Eduardo Felice Barbeiro

Editoração eletrônica
*Anapaula Rosário Lopes
Carlos Miguel Mascarenhas Carmo*

Fotos da capa
Romulo da Silva Carvalho

1ª edição
Publicação digital: PDF (2022)

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte,
constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP)

Embrapa Mandioca e Fruticultura

Carvalho, Romulo da Silva

Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros / Romulo da Silva Carvalho, José Eduardo Borges de Carvalho. – Cruz das Almas, BA : Embrapa Mandioca e Fruticultura, 2022.

45 p.: il. (Boletim de Pesquisa e Desenvolvimento/ Embrapa Mandioca e Fruticultura, ISSN 1809-5003, 137)

1. Equipamento digital. 2 Citros. 3 Cobertura de solo 4 Fruta cítrica I. Carvalho, Romulo da Silva II. Carvalho, José Eduardo Borges de III. Título. IV. Série.

CDD 631.3

Sumário

Resumo	5
Abstract	7
Introdução.....	9
Material e Métodos	11
Resultados e Discussão	30
Conclusões.....	41
Agradecimento	41
Referências	42

Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros

Romulo da Silva Carvalho

José Eduardo Borges de Carvalho

Resumo – A presente metodologia digital tem como objetivo estimar o percentual de cobertura do solo com gramíneas (*Urochloa* spp.) nas entrelinhas de pomares de citros para fins de pesquisa. Esse processo metodológico digital, combina ferramentas de processamento de imagens aéreas de aeronaves remotamente pilotadas (RPA) e softwares livres de código aberto Fiji ImageJ e Weka (*Waikato Environment for Knowledge Analysis*), sendo que este último utiliza algoritmos de última geração e técnicas de inteligência artificial (IA) da subárea de aprendizado de máquina (supervisionado). Utilizou-se o método preditivo de classificação de árvore de decisão tendo como algoritmo classificador *Random Forest*, que é acionado no software Fiji ImageJ a partir do plugin TWS (*Trainable Weka Segmentation*). Por meio da supervisão do pesquisador, um conjunto de entrada de padrões de pixels são rotulados e representados com suas características (atributos) e, em seguida, usados como um conjunto de dados para treinamento do algoritmo classificador. Uma vez que o modelo classificador é treinado, este é utilizado para classificar o restante de pixels de entrada da imagem ou em outras imagens com novos dados. Após o treinamento do modelo, procede-se com a segmentação e classificação da imagem da subamostra que gera, posteriormente, como resultado, uma nova imagem RGB a partir do plugin TWS. Posteriormente, procede-se com a transformação dessa imagem RGB para imagem tipo 8bit e, em seguida, faz-se o pós-processamento digital para limiarização/binarização da imagem para obtenção do percentual de

¹ Engenheiro-agrônomo, doutor em Ciências, pesquisador da Embrapa Mandioca e Fruticultura, Cruz das Almas, Bahia.

² Engenheiro-agrônomo, doutor em Solos e Nutrição de Plantas, pesquisador da Embrapa Mandioca e Fruticultura, Cruz das Almas, Bahia.

cobertura vegetal. O desempenho do modelo classificador treinado foi avaliado utilizando-se métricas gerais e qualitativas disponíveis no módulo *Explorer* do software Weka. Como resultado, verificou-se que todas as métricas de avaliação de desempenho do modelo indicaram excelente desempenho e adequação do modelo ao objetivo com alta acurácia (94,73%). Conclui-se que a presente tecnologia digital apresenta menor custo relativo para fins de pesquisa científica devido aos softwares gratuitos utilizados e poderá auxiliar na tomada de decisão sobre manejo de coberturas vegetais com gramínea *Urochloa* spp. nos pomares de citros, gerando dados mais precisos para se estimar o percentual de cobertura do solo.

Palavras-chave: Inteligência artificial. Processamento digital. Aprendizado de máquina supervisionado. Estimativa de cobertura vegetal. *Urochloa* spp. Citros. Manejo do Solo. Weka. Fiji ImageJ. Avaliação por imagem.

Digital processing and machine learning of aerial images from remotely piloted aircrafts (RPA) to estimate *Urochloa* spp. grass cover in citrus orchard.

Abstract – The present digital methodology aims to estimate the percentage of soil cover with grasses (*Urochloa* spp.) between the rows of citrus orchards for research purposes. This digital methodological process combines aerial image processing tools of remotely piloted aircraft (RPA) and free open-source software Fiji ImageJ and Weka (Waikato Environment for Knowledge Analysis), the latter of which uses state-of-the-art algorithms and artificial intelligence (AI) of the machine learning subarea (supervised). The decision tree classification predictive method was used with the *Random Forest* classifier algorithm, which is activated in the Fiji ImageJ software from the TWS (Trainable Weka Segmentation) plugin. Under researcher supervision, an input set of pixel patterns are labeled and represented with their characteristics (attributes) and then used as a dataset for training the classifier algorithm. Once the classifier model is trained, it is used to classify the remaining input pixels in the image or in other images with new data. After training the model, the subsample image is segmented and classified, which subsequently generates a new RGB image using the TWS plugin. Posteriorly, we proceed with the transformation of this RGB image to an 8-bit image and, then, the digital post-processing for thresholding/binarization of the image is carried out to obtain the percentage of grass cover. The performance of the trained classifier model was evaluated using general and qualitative metrics available in the Explorer module of the Weka software. As a result, it was found that all the performance evaluation metrics of the model indicated excellent performance and adequacy of the model to the objective with high accuracy (94.73%). It is concluded that the present digital technology has a lower relative cost for scientific research purposes due to the free software used and may help in decision making on the management of plant covers with *Urochloa* spp. in the citrus orchard, generating more accurate data to estimate the percentage of soil cover.

Keywords: Artificial intelligence. Digital processing. Supervised machine learning. Vegetation cover estimation. *Urochloa* spp. Citrus. Soil management. Weka. Fiji ImageJ. Evaluation by image.

Introdução

As coberturas vegetais nos cultivos de citros, quando bem manejadas, propiciam melhorias no solo e fornecem serviços ambientais que melhoram o equilíbrio fitossanitário e a produção do pomar (Adetunji et al., 2020).

A estimativa de cobertura vegetal no solo tem sido obtida por meio de métodos convencionais de inspeção visual e de transeção linear (Sloneker; Moldenhauer, 1977; Alves et al., 1998). Na avaliação visual, tem-se a vantagem da rapidez na execução, baixo custo e a possibilidade de distinção entre baixos percentuais de cobertura de diferentes espécies (Rizzardi; Fleck, 2004). Contudo, o método visual apresenta como desvantagem a subjetividade durante a avaliação (Ngouajio et al., 1998;1999).

Por esse motivo, Han e Hayes (1990 a; b) sugerem que na determinação da cobertura do solo os métodos devam ser menos subjetivos.

Nos estudos de coberturas vegetais, as técnicas digitais vêm se constituindo em ferramenta diferenciada e atual para a tomada de decisão sobre o manejo do solo. Novas técnicas digitais estão sendo desenvolvidas com o intuito de inovação, associando imagens aéreas de aeronaves remotamente pilotadas (*remotely piloted aircrafts* – RPA) a softwares de processamento de imagens de domínio público ou comerciais, utilizando técnicas de inteligência artificial (IA) que facilitam a segmentação e a classificação de imagens aéreas em estudos de cobertura vegetal no solo.

As RPAs se adaptam às necessidades de cada projeto e se tornaram ferramenta importante para a agricultura de precisão, destacando-se como novo meio técnico para extrair informação nas áreas da agricultura e meio ambiente (Morgan et al., 2010; King, 2017; Pessi et al., 2020). As RPAs apresentam como vantagens alta flexibilidade, facilidade de operação, alta resolução espacial e temporal, relativo baixo custo de aquisição/manutenção e rápida aquisição de dados que auxiliam na tomada de decisão reduzindo o tempo de observação no campo (Jorge e Crestana, 2007a; Mulla, 2013; Deng et al., 2018).

Mitchell (1997) define aprendizagem de máquina (do inglês *machine learning*) como a capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência. Nesse sentido, Domingos (2015) informa

que a tecnologia de aprendizado de máquina foi desenvolvida em resposta à rigidez de muitos programas de computador.

Na avaliação de cobertura por imagem, a distinção entre os tons das coberturas de espécies vegetais depende do software processador e de técnicas de inteligência artificial (IA), como as da subárea de aprendizado de máquina, que utiliza modelos matemáticos para treinar algoritmos, segmentar e classificar corretamente a imagem com base em padrões de pixels.

Segundo Xie et al. (2008), o uso de classificadores estatísticos que discernem recursos ou cobertura do solo com base em vários valores de refletância em diferentes bandas de ondas, compondo uma imagem ou aplicando conjuntos de regras predefinidas para classificar logicamente objetos segmentados da imagem, permite reconhecer objetos a partir de grande número de pixels.

Lima et al. (2015) compararam técnicas de estimativa de fração de cobertura das gramíneas *Urochloa ruziziensis* e *Urochloa* spp., sem utilizar técnica de IA na metodologia, e relataram dificuldade na análise para distinguir tons verde-claros das gramíneas pelo processador digital utilizado.

Por outro lado, Riegler-Nurscher et al. (2018) utilizaram a abordagem de aprendizado de máquina para classificar resíduos e a cobertura vegetal com base em pixels, alcançando precisão de 90% ao utilizar o recurso de árvore de decisão e o algoritmo classificador *Random Forest*.

Santos et al. (2020) avaliaram a qualidade da cobertura conforme o manejo do solo, utilizando procedimento metodológico que inclui técnica de IA, imagens aéreas de RPA e uso de softwares comerciais e gratuitos. Os autores utilizaram no plano de voo o software comercial (Pix4D®). Para gerar mapa ortomosaico, utilizaram o software comercial Agisoft Photoscan®, para obtenção da estimativa da taxa de cobertura do solo utilizaram o software gratuito Siscob (e, no processamento das imagens, o algoritmo quantificado por MPRI (Modified Photochemical Reflectance Index) (Jorge e Crestana, 2009b). Na visualização, edição e análise dos dados georreferenciados, utilizaram o software livre QGIS.

Portanto, embora existam diferentes metodologias para se avaliar as coberturas vegetais do solo, algumas são de uso simplificado e de execução rápida, mas apresentam subjetividade na avaliação, enquanto outras são

complexas e geralmente utilizam softwares comerciais no processo metodológico, o que aumenta o custo para obtenção dos resultados de pesquisa na avaliação das coberturas vegetais.

Em termos de softwares livres, o software Weka (*Waikato Environment for Knowledge Analysis*) agrega algoritmos de última geração provenientes de diferentes abordagens da subárea da IA sendo referência em mineração de dados e aprendizado de máquina (Hall et al., 2009). O plugin TWS (*Trainable Weka Segmentation*) integra o software de código aberto Fiji ImageJ sendo utilizado na segmentação supervisionada e classificação de pixels na área científica, principalmente, nas áreas de biologia e medicina (Arganda-Carreras et. al., 2017; Schindelin et al., 2012; Rueden et. al., 2017).

Portanto, novas técnicas adaptadas e softwares computacionais de código aberto ou comerciais que permitam o acompanhamento espacial e temporal das coberturas vegetais se constituem em importantes ferramentas metodológicas digitais para tomada de decisão do manejo do solo com coberturas vegetais.

Nessa perspectiva, objetiva-se apresentar processo metodológico digital de baixa complexidade e alta acurácia que permite determinar o percentual de coberturas vegetais de gramíneas *Urochloa* spp. nas entrelinhas de pomares de citros. Para tal, serão utilizadas imagens aéreas multitemporais obtidas de forma padronizada com aeronaves RPA e analisadas por softwares livres de código aberto. Estes utilizam processamento digital e técnica de inteligência artificial (IA) baseada em aprendizado de máquina supervisionado com o método preditivo de classificação, por meio de árvore de decisão com o algoritmo classificador *Random Forest*, acionado no software livre Fiji ImageJ a partir do plugin TWS para a determinação do percentual desejado.

Material e métodos

A presente metodologia digital visa estimar o percentual de cobertura do solo de gramíneas (*Urochloa* spp.) nas entrelinhas de pomar de citros por meio do uso de imagens aéreas de aeronaves RPA em baixa altitude.

Esse processo metodológico digital combina ferramentas de processamento de imagem com softwares livres de código aberto Fiji ImageJ e

técnica de inteligência artificial (IA) da subárea de aprendizado de máquina (*machine learning*) (Schindelin et al., 2012). Utiliza o software Weka (*Waikato Environment for Knowledge Analysis*) baseado em algoritmos de última geração escrito na linguagem Java (versão 3.8.5) e desenvolvido pela Universidade de Waikato, Nova Zelândia (Bouckaert et. al., 2020).

Portanto, o software Weka agrega algoritmos provenientes de diferentes abordagens da área da inteligência artificial dedicada ao estudo de aprendizado de máquina e mineração de dados (Bouckaert et al., 2020). No Weka, utilizou-se a opção *Explorer* para executar e gerar diversas métricas estatísticas que dizem respeito ao desempenho de algoritmos.

Utilizou-se também o software de processamento de imagens de código aberto Fiji ImageJ que contém o plugin TWS (*Trainable Weka Segmentation*) em seu sistema, que associa a técnica de aprendizado supervisionada de máquina às ferramentas de tratamento de imagens no software FIJI ImageJ. O TWS baseia-se no software Weka que transforma o problema da segmentação em problema de classificação de pixels (Vandenbroucke et al., 2003; Arganda-Carreras et. al., 2017).

Nesta metodologia digital, utilizou-se o método preditivo de classificação por meio de árvore de decisão com o algoritmo classificador *Random Forest* acionado no software livre Fiji ImageJ a partir do plugin TWS.

As técnicas de aprendizagem de máquina têm como objetivo a classificação de padrões que significa classificar um padrão desconhecido dentre várias classes possíveis (Aleen et al., 2015). Dessa forma, por meio do acompanhamento do pesquisador (supervisor), um conjunto de entrada de padrões de pixels são rotulados e representados com suas características (atributos) e, em seguida, usados como conjunto de dados para treinamento do algoritmo classificador *Random Forest*. Uma vez que o classificador é treinado, o modelo pode ser utilizado para que classifique o restante de pixels de entrada da imagem ou em outras imagens com novos dados (Figura 1).

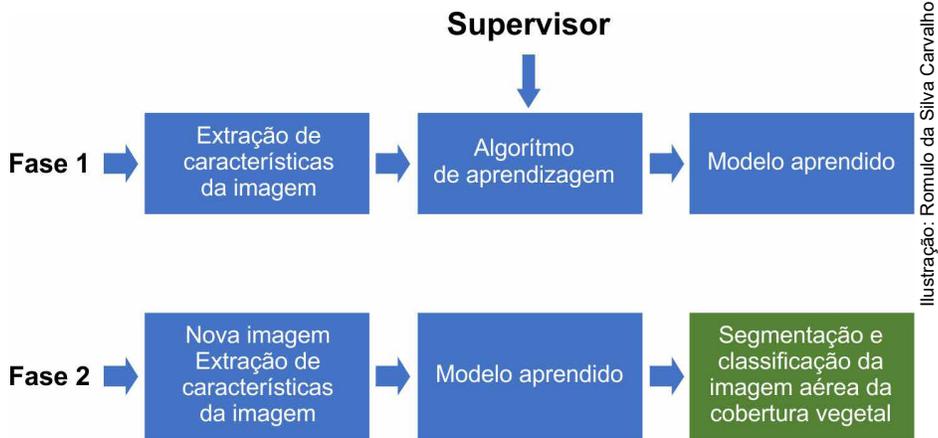


Figura 1. Etapas para segmentação e classificação supervisionada de imagens aéreas de cobertura de gramínea obtida com RPA.

Aquisição e pré-processamento das imagens aéreas

Na etapa de aquisição das imagens aéreas de RPA, utilizou-se aeronave do modelo DJI Phantom profissional equipado com câmera RGB e sensor 1/2.3" CMOS 'effective' acoplada a um 'gimbal' de 3 eixos.

As fotos digitais foram adquiridas nos formatos JPEG e DNG (Digital Negative = formato RAW), utilizando-se o padrão de exposição automática com ISO 100 1/2s, f/2.8 e EV +0.3 e bloqueio de exposição automática (AE) e, ainda, um filtro de densidade neutra (ND 8) acoplado à lente do RPA, com o propósito de absorver a luz refletida da cobertura vegetal de forma controlada.

A altitude de voo do RPA foi fixada em 10 m e o horário entre 10h e 11h de forma a diminuir a incidência de sombras nas imagens. Foram realizados oito voos com RPA para obtenção das imagens aéreas visando treinamento do modelo, totalizando 80 imagens para obtenção das subamostras, sendo utilizadas 40 para treinamento do algoritmo e 40 para testes de avaliação do modelo. Com relação ao pomar de citros, este é constituído da combinação copa de larajeira "Pera" e porta-enxerto limoeiro 'Cravo" com 15 anos de idade, localizado no município de Rio Real, Bahia.

Pré-processamento digital da imagem aérea original

Antes do processamento digital, torna-se necessário o preparo da imagem a ser analisada. Para isso, na fase de pré-processamento da imagem aérea original da cobertura vegetal, fez-se o redimensionamento e corte (*crop*) (Figura 2A) da imagem original com o intuito de evidenciar a área de interesse do estudo (Figura 2B) e facilitar a análise da estimativa da cobertura das gramíneas na imagem da subamostra (Figura 2C).

No procedimento de corte da imagem aérea original, demarcou-se a área de interesse gerando uma nova imagem (subamostra) a ser utilizada pelo plugin TWS para segmentação e classificação supervisionada de padrões de pixels na nova imagem da subamostra (Figura 2).

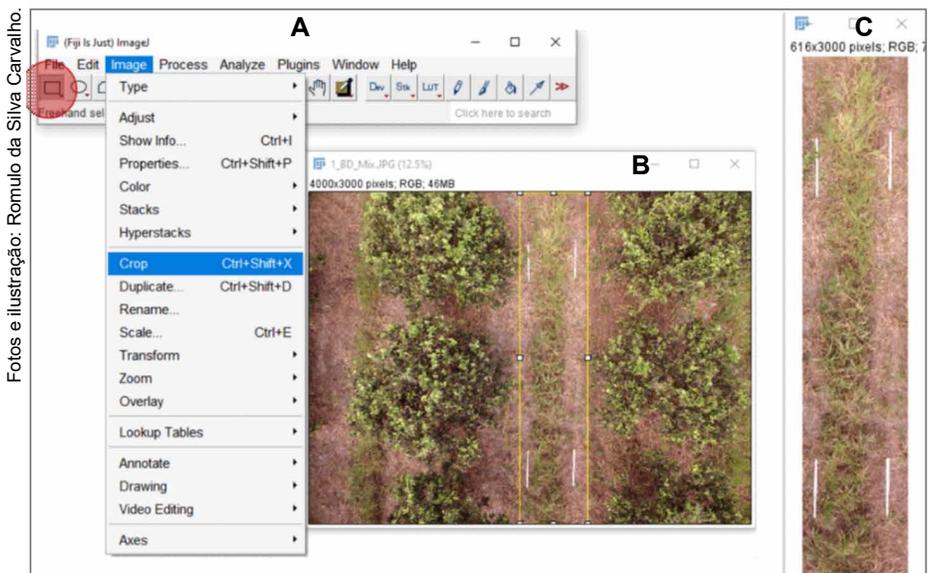


Figura 2. Sequência da etapa de redimensionamento e corte da imagem original para evidenciar a área de interesse na imagem aérea. O círculo vermelho indica a ferramenta de desenho “retangular” utilizada para seleção da área de interesse na entrelinha do pomar de citros; a letra (A) indica a sequência de comandos no software ImageJ para proceder o corte da imagem; a letra (B) indica o local demarcado da área de interesse na subamostra da gramínea na entrelinha dos citros e a letra (C) mostra o resultado do corte que gerou imagem da subamostra e que evidencia a área de interesse no estudo, estando pronta para segmentação e classificação supervisionada com o plugin TWS no software Fiji ImageJ.

Aprendizado de máquina utilizando o plugin TWS para segmentar e classificar de forma supervisionada pixels da área de interesse na subamostra da cobertura da gramínea.

Segundo Arganda-Carreras et al., (2017), a segmentação de imagens é o processo de particionar uma imagem digital em regiões sem interseção. Essas regiões ou segmentos compreendem conjuntos de pixels que compartilham certas características visuais (padrões de pixels) e recebem um rótulo específico (Classes).

A segmentação e a classificação de pixel na imagem da subamostra ocorreu após a conclusão do treinamento supervisionado do algoritmo e gerou um arquivo de dados (extensão. *arff* – *Attribute Relation Format File*) e um arquivo do modelo treinado (extensão. *model*) com base nos atributos indicados pelo supervisor na etapa de treinamento do algoritmo (Figura 3, n.1-10 e Figura 4).

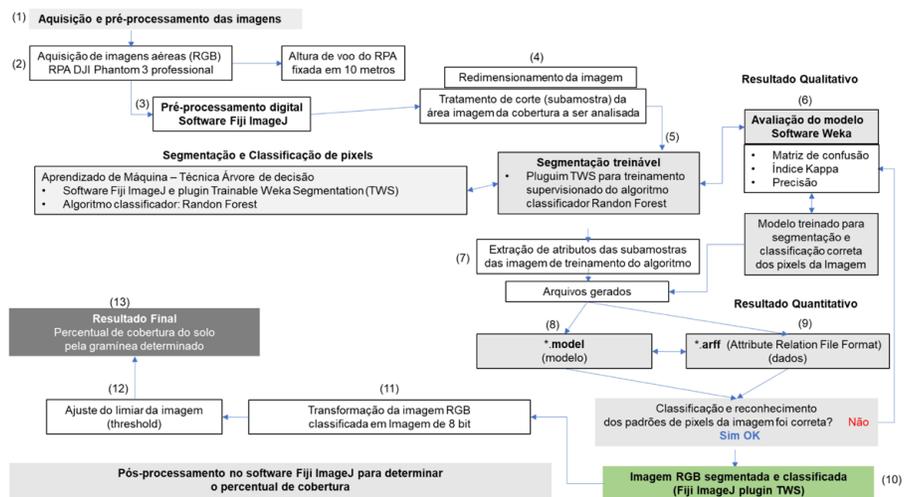


Figura 3. Diagrama do fluxo de trabalho do processamento digital para segmentação e classificação supervisionada de imagens aéreas obtidas de ARP visando estimar percentual de coberturas do solo com gramíneas nas entrelinhas de pomar de citros. Os números entre parênteses (n.1-10) se referem à primeira etapa metodológica para aquisição das imagens aéreas, pré-processamento, treinamento do algoritmo classificador, extração de atributos para segmentação e classificação supervisionada; os números (n.11-13) se referem à segunda etapa de pós-processamento da subamostra já segmentada e classificada, transformando-a de imagem tipo RGB para imagem 8-bit onde, posteriormente, ajusta-se do limiar (*threshold*) da imagem da subamostra para obter-se o resultado final do percentual de cobertura do solo com a gramínea nas entrelinhas de pomar de citros.

As características robustas (atributos) da imagem levaram em conta a variabilidade de pixels para distinguir uma classe no modelo de aprendizagem supervisionado (Figura 1). O algoritmo de aprendizagem gerou um modelo daquela imagem, extraindo seus principais atributos em forma de dados no arquivo com formato padrão do TWS (arff), que foi utilizado para estruturar a base de dados manipulada pelo software Weka (Figura 3, n.9 e Figura 4).

O plugin TWS dispõe de conjunto de bibliotecas e métodos para extrair da imagem digital fornecida pelo usuário as propriedades estatísticas obtidas de amostras pixel da imagem. O TWS utilizou essas informações para segmentação automática por meio de aprendizagem supervisionada do resto dos pixels naquela imagem ou em imagens semelhantes, gerando um arquivo modelo (.model) (Figura 1 e Figura 3, n.8) e outro de dados (.arff) que continha os atributos que permitiram a segmentação e classificação de novas imagens (Figura 3, n. 9 e Figura 4).

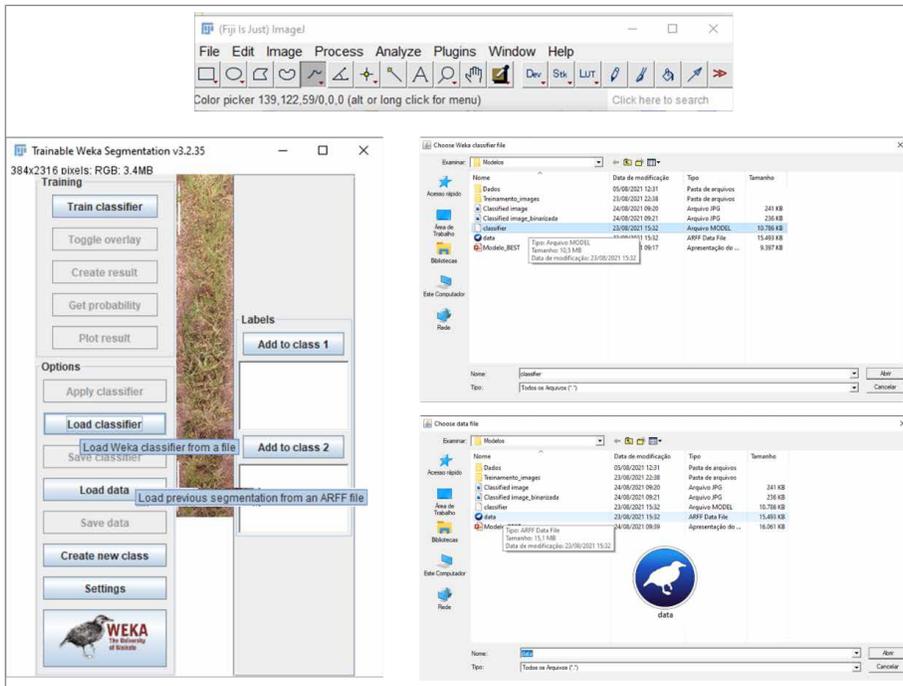
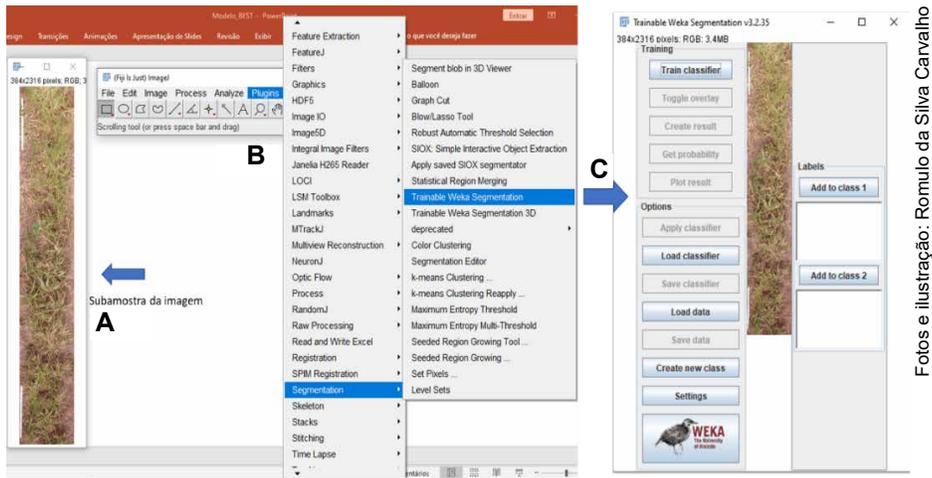


Figura 4. Locais para acessar e salvar os arquivos de dados ARFF (*Attribute Relation Format File*) e o arquivo do modelo (arquivo.model) classificador gerados e utilizados no treinamento e teste do algoritmos classificador.

Acionamento e execução do plugin TWS

Na Figura 5, demonstra-se como o plugin TWS foi acionado no software Fiji ImageJ para segmentação e classificação supervisionada dos pixels da imagem da subamostra (Figura 5B e C).



Fotos e ilustração: Romulo da Silva Carvalho

Figura 5. Sequência para acionamento do plugin TWS (*Trainable Weka Segmentation*) no software Fiji ImageJ visando a segmentação e classificação supervisionada da imagem aérea da subamostra da cobertura de gramínea na entrelinha de pomar de citros. A letra (A) indica a imagem da subamostra que contém a área de interesse na entrelinha dos citros; na letra (B), visualiza-se a barra de comando “plugins” no software Fiji ImageJ para acionamento e execução do plugin TWS (*Trainable Weka Segmentation*); a letra (C) indica a interface gráfica da primeira janela do plugin TWS, onde se observa a imagem da subamostra pronta para segmentação e classificação supervisionada.

Na execução do TWS duas etapas foram necessárias, sendo uma para o treinamento do algoritmo (Figura 3, n.6 e n.7) e a outra para avaliação do resultado (teste).

Aprendizagem supervisionada para execução do treinamento do algoritmo classificador no plugin TWS

Segundo Tharwat (2021), existem três fases principais no processo de classificação: treinamento, teste e validação. O modelo é treinado usando a entrada de padrões de pixels, sendo essa a fase de treinamento.

Um modelo em treinamento utiliza um conjunto de dados com entradas e atributos, sendo necessário conhecer o resultado esperado para esse conjunto de dados (Mariano, 2021). Essas informações serão usadas para treinar o modelo, utilizando um conjunto de dados (não usados no treinamento) para testar o quanto o modelo acerta para prever resultados esperados para novos dados que surgirem no futuro. Portanto, o treinamento do algoritmo classificador é a etapa mais importante para segmentação e classificação de pixels na imagem da subamostra.

Segundo Arganda-Carreras et al., (2017) a segmentação é o processo de particionar uma imagem digital em regiões sem interseção. Segundo os autores, essas regiões ou segmentos compreendem conjuntos de pixels que compartilham características visuais e recebem um rótulo específico. Na segmentação ocorre o particionamento da imagem em segmentos não sobrepostos que formam a base das informações que serão transportadas para as etapas de processamento subsequentes como o reconhecimento de objeto, a classificação de imagens ou a extração de informações (Trias-Sanz et al., 2008; Yang et al., 2015).

Na Figura 6, observa-se a interface do software Fiji ImageJ e as ferramentas de desenho utilizadas para demarcar áreas de interesse na imagem da subamostra que representaram as respectivas classes durante o treinamento do algoritmo no plugin TWS. Durante o treinamento do algoritmo classificador, o usuário adicionou traços ou formas que as caracterizaram de forma a indicar para o algoritmo quais eram os padrões de pixels que representavam cada classe. Todo o conjunto de traços e formas encontram-se disponíveis na barra de ferramentas de desenho do software Fiji ImageJ (Figura 6F).

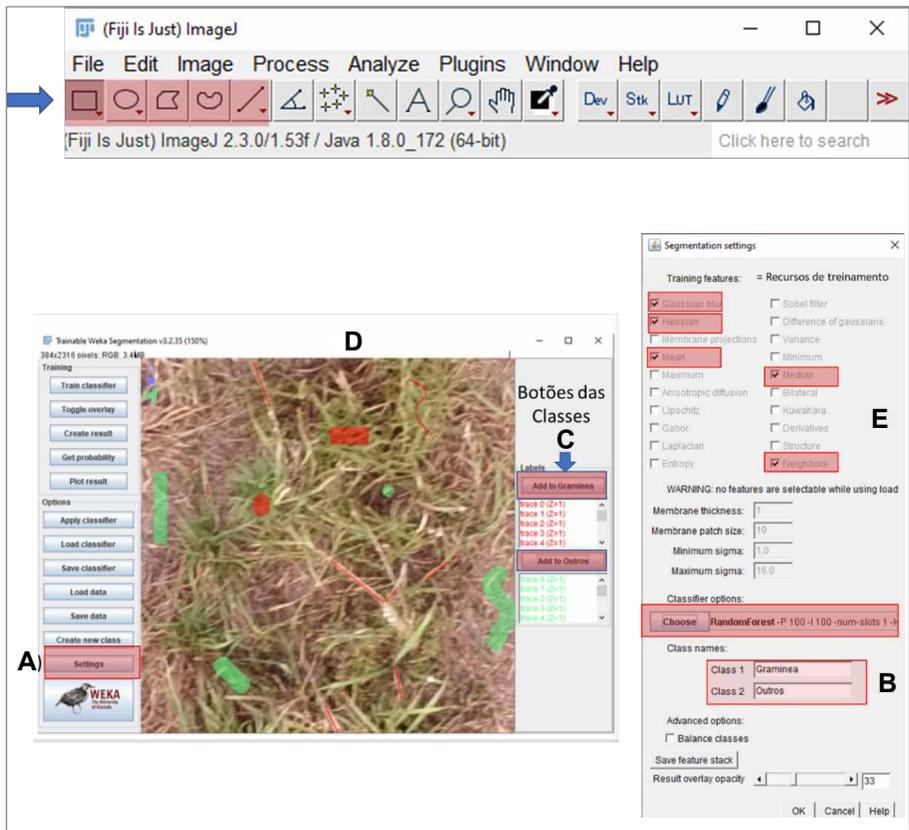


Ilustração e foto: Romulo da Silva Carvalho

Figura 6. Fase de treinamento do algoritmo mostrando a interface do plugin TWS onde na letra (A) se visualiza o acesso à configuração (*settings*) no TWS; na letra (B), observa-se o local para nomear as classes criadas “Gramínea” e “Outros”; na letra (C), observa-se o local onde são indicados os traços e formas que caracterizam as respectivas classes; na letra (D), exemplificam-se os tipos de traços e formas que indicarão os atributos de interesse de cada classe indicadas pelo supervisor, onde a cor vermelha mostra as características selecionadas dos pixels referente à Classe “Gramínea” e, na cor verde, as características representativas da classe “Outros”; na letra (E), encontram-se os recursos de treinamento (*training features*) utilizados no treinamento do algoritmo e a opção para selecionar um algoritmo classificador (*classifier*) no plugin TWS; na letra (F), verificam-se a interface do software Fiji ImageJ e o local da barra de ferramentas de desenhos utilizadas para indicar os atributos das classes.

Por padrão, o plugin TWS inicia com duas classes (Figuras 5C e Figura 6B) e produzirá classificação de pixels binários. Para nomear as classes, o usuário clicou no botão de configuração “*settings*” localizado no lado esquerdo da interface do plugin TWS (Figura 6A e B,C). Dessa forma, os nomes das classes foram definidos como classe 1 “Gramínea” (espécie de interesse), com traços de treinamento das características identificados na cor vermelha, e classe 2, denominada de “Outros”, que engloba o solo, sombras, palhada e vegetação espontânea sendo identificada com traços na cor verde (Figura 6B e C).

No lado esquerdo da interface do TWS há dois painéis de botões, um para ser utilizado no treinamento do algoritmo e o outro para opções gerais (Figura 6). Na Figura 6F, observa-se um painel de barra de ferramenta de desenho do software Fiji ImageJ que foi utilizado para indicar traços característicos dos atributos de cada classe e, na Figura 6B, visualiza-se um botão utilizado para adicionar os traços de pixels característicos da região de interesse de uma classe específica. Todos os botões contêm uma breve explicação de suas funcionalidades que é exibida quando o cursor do mouse permanece sobre os botões.

O usuário pode movimentar, aumentar e diminuir o zoom da imagem da subamostra de forma a facilitar a demarcação dos pixels que representam os atributos característicos de cada classe, utilizando-se o comando CLTR + para aumento e CLTR - para diminuição do tamanho da imagem.

Ao selecionar o algoritmo (*Classifier options*, Figura 6), foi possível configurá-lo para execução sobre as opções do conjunto de treinamento (*training features*). As configurações utilizadas nos recursos de treinamento nesta metodologia digital estão indicados na Figura 6E que, juntamente do algoritmo classificador *Random Forest* (“*classifier*”), possibilitaram a obtenção do melhor resultado para segmentação e classificação supervisionada da subamostra da cobertura do solo com gramínea.

Durante a fase aprendizagem supervisionada do algoritmo, foi fundamental coletar as principais características discriminantes da área de interesse (Figura 6C, D e F) para que o modelo tivesse maior precisão. Na extração dessas características, todos os atributos relevantes dos pixels da imagem geraram uma base de dados (arquivos arff) que foi submetida ao algoritmo classificador *Random Forest*.

O número e nomes das classes e o algoritmo de aprendizagem desejado foram definidos pelo usuário no plugin TWS (Figura 6). Durante a fase de treinamento do algoritmo, utilizaram-se as ferramentas de desenho do software ImageJ para a seleção das classes no plugin TWS (Figura 6F). Nesse processo, o supervisor indicou quais pixels (partes da imagem) da subamostra eram pertencentes a cada classe por meio de análise visual das feições da cobertura e uso do solo (Figura 6C, D).

O supervisor indicou ao plugin TWS quais eram as características de interesse na imagem e as colocou na classe específica correspondente a qual ela pertencia, se classe “Gramínea” ou classe “Outros”, gerando uma base de dados no arquivo arff (Figura 3, n.9; Figura 4).

Durante o treinamento do modelo, novas e diferentes imagens foram colocadas no plugin TWS para treinamento até que se obtiveram os melhores resultados nas métricas de avaliação do modelo e na segmentação e classificação da imagem da subamostra analisada.

O processo de treinamento do algoritmo classificador foi repetido até gerar os melhores resultados de classificação de pixels em cada classe especificada da imagem no TWS (Figura 3, n.6 e Figura 6).

Transformação da imagem classificada da subamostra RGB para 8bit e ajuste de limiar (threshold) para cálculo do percentual da cobertura da gramínea no solo.

Após o treinamento do modelo, segmentação e classificação da imagem da subamostra, nova imagem RGB foi gerada como resultado no plugin TWS. Posteriormente, no software Fiji ImageJ, procedeu-se a transformação de imagem tipo RGB para tipo 8-bit e, logo em seguida, realizou-se o procedimento de limiarização/binarização da imagem de 8-bit (Figura 7) para obtenção automática do percentual de cobertura vegetal com a gramínea na entrelinha de pomar de citros.

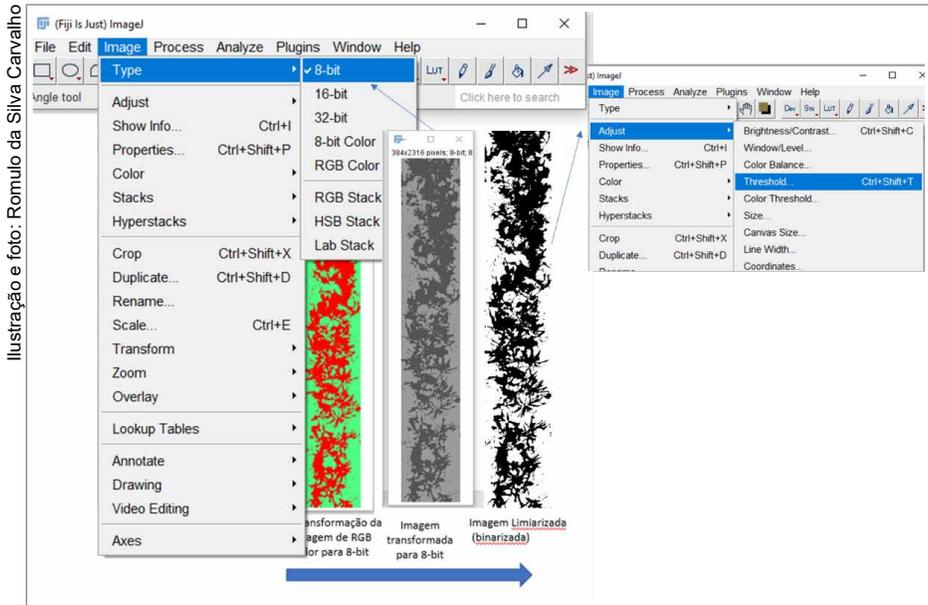


Figura 7. Procedimento para transformação da imagem da subamostra RGB classificada no plugin TWS para imagem de tipo 8-bit e posterior ajuste do limiar (*threshold*) para binarização da imagem onde se destaca a área de interesse na subamostra para posterior determinação do percentual de cobertura vegetal.

A limiarização consistiu em separar regiões da imagem em duas classes (fundo e objeto de interesse = gramínea) e permitiu reduzir os tons de cinza na imagem original, possibilitando produzir uma imagem binária (binarização) que apresentava as cores em preto (objeto de interesse) e branco (fundo da imagem).

Desempenho do algoritmo modelo de classificação binária de pixels

As métricas de validação dos modelos de *Machine Learning* foram utilizadas para analisar a sua qualidade por meio da informação do desempenho do modelo em dados desconhecidos. A classificação binária foi utilizada para prever um dos dois resultados possíveis. Em modelos de

aprendizado supervisionado, o objetivo é tentar estimar se uma determinada variável pertence à classe “Gramínea” ou à classe “Outros”. Portanto, diferentes métricas de validação do modelo são utilizadas para análise do seu poder preditivo.

Segundo Tharwat (2021), o método de avaliação é um fator-chave na avaliação do desempenho da classificação, orientando a modelagem do classificador. Segundo o autor, os padrões de entrada são chamados de treinamento dados e são usados para treinar o modelo. Durante esta fase, os parâmetros de um modelo de classificação são ajustados. O erro de treinamento mede o quão bem o modelo treinado se ajusta aos dados de treinamento. Segundo o autor, na fase de validação, os dados fornecem uma avaliação imparcial do modelo treinado enquanto ajusta os hiperparâmetros do modelo.

De acordo com Sokolova et al. (2006), as métricas de desempenho existentes avaliam diferentes características dos algoritmos de aprendizado de máquina sendo, portanto, importante verificar o desempenho de um método com o auxílio de várias métricas.

Estimativa de desempenho preditivo do modelo utilizando validação cruzada (*cross validation*)

Para analisar o desempenho preditivo do modelo treinado, foi utilizada a validação cruzada (*cross validation*) que envolveu a divisão de uma amostra de dados em subconjuntos complementares, executando a análise de um subconjunto de treinamento e validando a análise em outro subconjunto de validação (Diamantidis et al., 2000). Na presente metodologia digital, foram utilizadas 10 dobras (*folds*) para a estimativa de validação cruzada a partir do arquivo de dados ARFF, cujo acesso ao arquivo de dados é mostrado na Figura 4.

Ao clicar no módulo Explorer, selecionou-se a aba *Preposses* para carregar o arquivo de dados ARFF contido em diretório específico do usuário. Após carregar o arquivo ARFF, selecionou-se a aba *Classify* para selecionar o algoritmo classificador em *Classifier* (*choose*). Em seguida, selecionou-se *Tree* que indicava os locais onde se encontravam diferentes algoritmos de árvores de decisão e se selecionou o algoritmo *Random Forest*. Após

carregar o algoritmo em *Test options*, selecionou-se *Cros-validation 10 folds* e, em seguida, *start*. O software Weka apresentou como resultado a saída de métricas gerais e qualitativas.

Segundo Bouckaert et al. (2020), com a validação cruzada pode-se criar várias amostras (ou dobras = *folds*) a partir do conjunto de dados de treinamento do modelo. Segundo os autores, se você decidir criar N dobras, o modelo será executado iterativamente N vezes. Cada vez que uma das dobras é retida para validação, N - 1 dobras restantes são usadas para treinar o modelo. O resultado de todas as dobras é calculado para fornecer o resultado da validação cruzada, obtendo-se uma estimativa de desempenho preditivo do modelo treinado.

Neste trabalho, o desempenho do modelo classificador *Random Forest* com duas classes (binário) foi avaliado utilizando-se um conjunto de dados qualitativos (*data set*) contidos no arquivo ARFF (Figura 4), que foi gerado após o treinamento supervisionado do modelo. Foram consideradas na avaliação da performance do modelo as principais métricas em modelos de classificação binária disponíveis no módulo *Explorer* do software Weka, que foram revisadas, descritas e explicadas por Bouckaert et al. (2020) e Tharwat (2021) e estão apresentadas a seguir:

Matriz de confusão

A matriz de confusão é importante para avaliação do modelo, pois os dados contidos descrevem o resultado da classificação de cada registro, e por meio dela se obtêm as demais métricas.

Segundo Vujović (2021), em uma matriz de confusão para um classificador binário, os valores reais são marcados como verdadeiro (1) e falso (0) e são previstos como positivo (1) e negativo (0). As estimativas das possibilidades de modelos de classificação são derivadas das expressões VP, VN, FP, FN que existem na matriz de confusão. Na Tabela 1, mostra-se exemplo conceitual representando os resultados de um método de classificação de dados por meio da matriz de confusão.

Tabela 1. Matriz de confusão para o problema de classificação binária adaptada de Vujović (2021).

Designação de classe	Classe Atual		
	Verdadeiro (1)	Falso (0)	
Classe Preditada	Positivo (1)	VP (=TP)	FP
	N negativo (0)	FN	VN (=TN)

Onde:

- P (positivo) = TP + FN ; N (negativo) = FP + VN.
- VP (=TP) = Verdadeiro positivo: quando o método diz que a classe é positiva e, ao verificar a resposta, vê-se que a classe era realmente positiva, ou seja, VP indica a quantidade de registros que foram classificados como positivos corretamente.
- VN (=TN) = Verdadeiro negativo: quando o método diz que a classe é negativa e, ao verificar a resposta, vê-se que a classe era realmente negativa, ou seja, VN indica a quantidade de registros que foram classificados como negativos de maneira correta.
- FP = Falso positivo: quando o método diz que a classe é positiva, mas ao verificar a resposta, vê-se que a classe era negativa, ou seja, indica a quantidade de registros que foram classificados como positivos de maneira incorreta.
- FN = Falso negativo: quando o método diz que a classe é negativa, mas ao verificar a resposta, vê-se que a classe era positiva, ou seja, indica a quantidade de registros que foram classificados como negativos de maneira incorreta.

A partir desses valores, calcularam-se as métricas de acurácia (*accuracy*), precisão (*precision*), rechamada ou sensibilidade (*recall*) e F-Measure (=F1 Score).

Métricas utilizadas na avaliação do modelo classificador binário

Recall (Sensibilidade) ou taxa de verdadeiro positivos [do inglês True Positive Rate (TPR)]

Segundo Bouckaert et al. (2020), a taxa de verdadeiros positivos é a proporção de exemplos do treinamento que foram classificados como classe x , entre todos os exemplos que realmente têm classe x , ou seja, quanto parte da classe foi capturada. É equivalente a *Recall*. Na matriz de confusão este é o elemento diagonal dividido pela soma sobre a linha relevante (Tabela 1). A métrica *Recall* também denominada de *sensibilidade* ou taxa de verdadeiro positivo (TPR), dá ênfase aos erros por falso negativo, sendo definida pela razão entre a quantidade de exemplos classificados corretamente como positivos e a quantidade de exemplos que são de fato positivos. As fórmulas das taxas de VP (verdadeiro positivo) e FP (falso positivo) são dadas pelas equações:

TVP (= TP - True Positive Rate) (= Sensibilidade ou recall)].

$$\text{Recall (= Sensibilidade)} = \frac{VP}{VP + FN} = \frac{VP}{P}$$

$$\text{Taxa VP (classe Gramínea): TVP} = \frac{VP}{VP + FN}$$

$$\text{Taxa VP (classe Outros): TVP} = \frac{VN}{VN + FP}$$

Segundo Tharwat (2021), a taxa verdadeira positiva (TVP) (sensibilidade ou *recall*) é calculada como o número de previsões positivas precisas (TP = VP) dividido pelo número total de positivas (P), sendo também chamada de Sensibilidade ou Rechamada (Recall). Segundo o autor, a melhor TVP é 1,0 e a pior 0,0.

A *recall* (sensibilidade) é bastante útil quando precisamos minimizar os falsos negativos, pois sempre que precisarmos minimizar os falsos negativos, devemos buscar um maior percentual no *recall*.

Taxa de falsos positivos [False Positive (FP) rate]

Segundo Tharwat (2021), a taxa de falsos positivos é calculada como o número de previsões de falsos positivos (FP) dividido pelo número total de negativos (N). A melhor taxa de falsos positivos é 0,0 e a pior é 1,0.

A taxa de FP estima a probabilidade de um exemplo pertencente à classe negativa ser predito como positivo.

$$\text{Taxa FP (classe Gramínea): } TFP = \frac{FP}{FP + VN}$$

$$\text{Taxa FP (classe Outros): } TFP = \frac{FN}{FN + VP}$$

F-Measure (= F₁-score)

Segundo Tharwat (2021), F-Measure (ou F1-score) é uma medida da precisão, e representa a média harmônica entre precisão e *recall*. Em termos de interpretação do resultado, o valor da F-Measure varia de 0 a 1, sendo que altos valores de indicam alto desempenho de classificação, sendo calculado pela fórmula:

$$F\text{-Measure (= } F_1\text{-score)} = 2X \frac{\text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}}$$

Coefficiente de correlação de Matthews (MCC - *Matthews Correlation Coefficient*)

O coeficiente de correlação de Matthew (MCC) é uma medida utilizada para verificar a classificação geral do modelo. Segundo Tharwat (2021), o MCC é a correlação entre as classes preditas e a verdade básica. É calculado com base nos valores da matriz de confusão. Segundo o autor, o MCC é geralmente considerado uma medida balanceada que pode ser usada mesmo se as classes forem de tamanhos muito diferentes.

$$MCC = \frac{VP}{\sqrt{(VP+FP)(VP+FN)(VN+FP)(VN+FN)}}$$

Em termos de interpretação, a métrica MCC apresenta valores no intervalo entre -1 e +1, sendo que o valor mais próximo de 1 indica uma classificação perfeita e, portanto, mais ajustada está a predição aos resultados observados. O valor 0 indica classificação aleatória e o valor -1 mostra total discordância entre a classificação feita e observada pelo supervisor.

Área ROC (*Receiver Operating Characteristic*)

Segundo Tharwat (2021), área ROC (do inglês, *receiver operating characteristic*) é um gráfico que visualiza troca entre taxa de verdadeiros positivos (TVP) e taxa de falsos positivos (TFP). Segundo o autor, para cada limiar, calcula-se TVP e TFP e se plota num gráfico. Os melhores classificadores têm maior curva para a esquerda.

A área sob a curva, conhecida com ROC AUC score (*area under the curve*), é usada como uma medida de qualidade, ou seja, um número que determina se a curva ROC é boa. Segundo Hanley (1989), a AUC é o resultado da integração de todos os pontos durante o trajeto da curva e computa simultaneamente a sensibilidade e a especificidade, sendo um estimador do comportamento da acurácia global do teste, ou seja, a AUC fornece uma estimativa da probabilidade de classificação correta de um sujeito ao acaso (acurácia do teste). Hosmer e Lemeshow (2000) sugerem uma regra geral para a classificação da capacidade de discriminação, dependendo do valor AUC:

- $\leq 0,5$ Não tem poder discriminativo
- $0,5-0,7$ Discriminação fraca
- $0,7-0,8$ Discriminação aceitável
- $0,8-0,9$ Discriminação boa
- $\geq 0,9$ Discriminação excelente

Área de PRC (*Precision-Recall Curve Area*)

Segundo Tharwat (2021), a área de PRC é um número que descreve a capacidade do modelo, sendo a melhor capacidade 1,0 e a pior 0,5. A curva PRC é obtida combinando o valor preditivo positivo e a taxa positiva verdadei-

ra. Para cada limite, o valor preditivo positivo e a taxa positiva verdadeira são calculados e o ponto correspondente do gráfico é traçado. Uma boa curva PRC tem uma AUC mais alta.

Precisão (*Precision*)

Segundo Tharwat (2021), o conceito de precisão está associado à ideia de medida e de repetição. Segundo o autor, a precisão é a proporção dos exemplos que realmente dispõem de classe x entre todos aqueles que foram classificados como classe x . Na matriz de confusão este é o elemento diagonal dividido pela soma da coluna relevante. A precisão é calculada como o número de previsões positivas corretas (TP), dividido pelo número total de previsões positivas (TP + FP). Em termos de interpretação dos resultados, o melhor valor da precisão é 1,0 e o pior 0,0.

$$\text{Precisão classe Graminea } P = \frac{VP}{VP+FP}$$

$$\text{Precisão classe Outros } P = \frac{VN}{VN+FN}$$

Acurácia (*Accuracy*)

Medidas acuradas são aquelas cujo valor se aproxima do valor correto, ou seja, valor de referência. De acordo com Sokolova et al. (2006), a acurácia (Acc) é uma das medidas mais comumente usadas para o desempenho de classificação, sendo definida como a razão entre as amostras classificadas corretamente e o número total de amostras. Segundo Tharwat (2021), essa medida avalia quão efetivo um algoritmo é, mediante a probabilidade deste realizar previsões corretas. A acurácia corresponde às instâncias corretamente classificadas, sendo calculada como a soma de duas previsões precisas (TP + TN) dividida pelo número total de conjuntos de dados (P + N). Sendo a melhor precisão (acurácia) 1,0 e a pior é 0.

$$\text{Acurácia (ACC)} = \frac{VP+VN}{VP+VN+FP+FN} = \frac{VP+VN}{P(VP+FP)+N(VN+FN)}$$

Estatística Kappa

O software Weka disponibiliza na sua interpretação dos dados a estatística Kappa, que avalia o nível de concordância e ligação dos dados dentro de uma base de dados sendo que, se o número estatístico ficar próximo do 0 (zero), significa uma maior discordância das informações, e ficando o mais próximo do 1 (um) indica maior ligação e concordância.

Nessa metodologia digital, na análise qualitativa do valor de Kappa, o resultado foi comparado com base nos intervalos definidos em Landis e Koch (1977) (Tabela 2).

Tabela 2. Valores da Estatística Kappa.

K	Interpretação
≤ 0	Nenhuma concordância
0,01 a 0,2	Leve concordância
0,21 a 0,4	Concordância regular
0,41 a 0,6	Concordância moderada
0,61 a 0,8	Concordância substancial
0,81 a 1	Concordância quase perfeita

Fonte: Adaptado de Landis e Koch (1977).

Resultados e discussão

Estimativa de validação cruzada (*cross validation*)

A estimativa de validação cruzada é uma forma de avaliar como o modelo se comporta diante de variações nas amostras de treinamento, ajudando a evitar um dos problemas da influência da divisão dos dados na métrica. Os testes são feitos com dados que o modelo não viu anteriormente. Segundo Bouckaert et al. (2020), o resultado de todas as dobras é calculado para fornecer o resultado da validação cruzada, obtendo-se uma estimativa de desempenho preditivo.

Na presente metodologia digital, foram utilizadas 10 dobras (*folds*) para a estimativa de validação cruzada cujos resultados são detalhados por classe nas Tabelas 4 e 5 e apresentados a seguir:

Matriz de confusão

Nesse trabalho, as duas classes avaliadas foram denominadas de classe 1 “Gramínea” e Classe 2 “Outros” sendo, portanto, uma matriz de confusão 2x2. Na Tabela 3, podem ser vistos os resultados apresentados na matriz de confusão que mostraram altos valores de acerto, tanto na classe “Gramínea” quanto na classe “Outros”. Com base na acurácia, observou-se que a classe “Gramínea” apresentou maior erro de falsos positivos em relação à classe “Outros”. Os erros de classificação entre estas classes ocorreram devido a confusões em áreas com vegetação mais esparsa e áreas de sombra. Entretanto, os valores de acurácia apresentados por estas classes são altos.

A matriz de confusão fornece um modo visual para o pesquisador verificar como o modelo treinado está cometendo erros em sua previsão das classes. A palavra “confusão” corresponde às amostras classificadas de forma incorreta.

Segundo Congalton e Green (2009), a matriz de confusão se constitui em insumo para a geração de índices que visam avaliar a exatidão da classificação.

De acordo com Narkhede (2018), a matriz de confusão é uma medida de desempenho para classificação de aprendizado de máquina, sendo extremamente útil para medir recall, precisão, especificidade, acurácia e curvas AUC-ROC.

Tabela 3. Matriz de confusão gerada no software Weka para análise qualitativa do modelo treinado com o algoritmo classificador Random Forest para as classes a = Gramínea e b = Outros.

a	b	Classificado como:	
3830 (VP)	184 (FN)	a =	Gramínea
223 (FP)	3494 (VN)	b =	Outros

Na matriz de confusão (Tabela 3), visualizam-se os valores reais nas colunas e os valores preditos nas linhas. Assim, o cruzamento das linhas e das colunas são os resultados das métricas gerais utilizadas pelo software Weka para medir a acurácia do algoritmo classificador *Random Forest*.

Na matriz de confusão, existem dois tipos de acertos e dois tipos de erros. Nos acertos, verifica-se que, para a classe “Gramínea”, 3830 pixels foram classificados como **verdadeiros positivos (TP)**, ou seja, a classe era 1 como “Gramínea” e o algoritmo identificou como 1 “Gramínea”. Para classe “Outros”, o modelo do algoritmo classificador *Random Forest* classificou 3494 pixels como **verdadeiros negativos (TN)**, pois a classe era 0 e o modelo previu como 0.

Em relação aos erros, o modelo classificou 223 pixels como falso positivos (FP), ou seja, o modelo previu como “Gramínea” quando na verdade não era uma “Gramínea”, e classificou 184 pixels como falsos negativos (FN), ou seja, o modelo previu como sendo da classe “Outros”, quando na verdade era pertencente à classe “Gramínea”.

Acurácia (instâncias corretamente classificadas)

Nesse trabalho, os valores médios das instâncias classificadas corretamente (acurácia) e incorretamente foram de 94,73% e 5,26%, respectivamente (Tabela 4), com esse resultado demonstra adequação do modelo treinado ao objetivo de segmentar e classificar de forma precisa a imagem aérea da subamostra de cobertura da gramínea na entrelinha do pomar de citros.

Em termos da métrica geral de acurácia, Varella et al. (2002) desenvolveram programa computacional com abordagem de IA utilizando redes neurais para estimar a cobertura do solo a partir de imagens digitais. Com base no valor do coeficiente Kappa, os autores concluíram que o classificador desenvolvido apresentou desempenho satisfatório para separar o solo das plantas com acurácia global de 82,10%, considerando como aceitável para esse índice, e afirmaram que redes neurais podem ser utilizadas para separar feições em que a diferença entre a intensidade do brilho não permite a aplicação da técnica da limiarização.

Tabela 4. Principais métricas gerais usadas neste trabalho para medir a performance de classificação binária a partir do algoritmo classificador *Random Forest*. Valores gerados pelo software Weka.

	Classificador <i>Random Forest</i>	
	Número	Percentual (%)
Instâncias corretamente classificadas (= Acc acurácia)	7324	94,7355
Instâncias incorretamente classificadas	407	5,2645
Estatística Kappa (valores de referência na Tabela 2)	0,8945	-
Número total de instâncias	7731	

Estatística Kappa

Nesse trabalho, no modelo treinado com o algoritmo classificador *Random Forest*, o valor obtido para o índice Kappa foi de 0,8945 (Tabela 3), indicando que as instâncias classificadas pelo modelo de aprendizado de máquina apresentaram elevado nível de concordância e ligação dos dados dentro da base de dados, e maior ligação e concordância quase perfeita do modelo treinado (Tabela 4) gerando, portanto, poucas classificações incorretas de pixels na matriz de confusão.

A estatística Kappa mede a concordância de previsão com a verdadeira classe, ou seja, esse índice mede a precisão de uma classe ou grau de acerto ou concordância desta classe (ver valores na Tabela 2) (Bouckaert et. al., 2020).

Recall (= Sensibilidade) ou taxa de verdadeiros positivos (TVP)

A métrica Recall nos informa sobre falsos negativos, sendo útil para minimizar os falsos negativos. Uma maior pontuação nessa métrica indica o quanto nosso modelo está identificando os casos positivos corretamente. Segundo Tharwat (2021), a melhor TVP é 1,0 e a pior 0,0.

Em nosso modelo de classificação binário para classe “Gramínea”, o valor de *Recall* foi de 0,954 e para a classe “Outros” foi de 0,940, indicando

que o modelo está classificando corretamente a maioria dos pixels das respectivas classes, ou seja, indicando que o modelo treinado tem a capacidade de prever corretamente os pixels das classes que realmente estão associados (Tabela 5).

Tabela 5. Valores das métricas geradas no software Weka para análise da performance do algoritmo classificador *Random Forest*, por classe, após treinamento supervisionado do modelo para segmentação e classificação de imagem aérea da subamostra de gramínea nas entrelinhas de pomar de citros, visualiza-se também a tabela referência dos melhores e piores valores métricos detalhados para cada classe de acurácia de acordo com Vujović (2021).

Métricas qualitativas geradas no software Weka								
Classes	Taxa VP	Taxa FP	Precisão	Recall	F-Measure	MCC	ROC	PRC
Gramínea	0,954	0,060	0,945	0,954	0,950	0,895	0,989	0,988
Outros	0,940	0,046	0,950	0,940	0,945	0,895	0,989	0,989
Média	0,947	0,053	0,947	0,947	0,947	0,895	0,989	0,988

Tabela de valores de referência (VUJOVIĆ, 2021)																
Valores de referência	M	P	M	P	M	P	M	P	M	P	M	P	M	P	M	P
		1	0	1	0	1	0	1	0	1	0	1	0	1	0,5	1

Onde: M = melhor desempenho e P = pior desempenho

Taxa de Falsos Positivos [False Positive (FP) rate]

A métrica taxa de falsos positivos (TFP) pode ser interpretada com a proporção de previsões negativas que foram determinadas como positivas para o número total de previsões negativas, ou seja, estima a probabilidade de um exemplo pertencente à classe negativa (classe “Outros”) ser predito como positivo (classe “Gramínea”). Segundo Tharwat (2021), a melhor taxa de falsos positivos é 0,0 e a pior é 1,0.

Nessa metodologia digital, os valores da TFP para a classe “Gramínea” foi de 0,060 e para a classe “Outros” foi de 0,046 (Tabela 5), indicando menor probabilidade de o modelo estimar pixels da classe “Outros” (previsão negativa) como sendo pertencentes à classe “Gramínea” (previsão positiva).

Precisão (*Precision*)

A precisão como métrica qualitativa traz a informação da quantidade de observações classificadas como classe “Gramínea” que realmente são pertencentes à “Gramínea”, ou seja, entre todos os pixels classificados como pertencente à classe “Gramínea”, quantas foram identificadas corretamente. Essa métrica demonstra a capacidade do modelo treinado evitar a classificação de amostras de pixels da imagem da classe “Outras” (negativo) como sendo pertencente à classe “Gramínea” (positivo).

Segundo Tharwat (2021), em termos de interpretação dos resultados, o melhor valor da precisão é 1,0 e o pior 0,0 (Tabela 5). No nosso modelo treinado a partir do algoritmo classificador *Random Forest*, o valor da precisão calculado no software Weka foi de 0,945 para a classe “Gramínea” e de 0,950 para a classe “Outros” (Tabela 5). Esse resultado indica, por exemplo, que a cada 100 pixels classificados pelo modelo treinado como pertencente à classe “Gramínea” (positivo), é esperado que 94,5 pixels sejam de fato pertencente à classe “Gramínea”.

- **F-Measure (= F_1 -score)**

Neste trabalho, o valor obtido para F-Measure foi de 0,950 para a classe “Gramínea” e de 0,945 para “Outros”, sendo a média 0,947 (Tabela 5), indicando o bom desempenho do algoritmo classificador *Random Forest* em prever pixels pertencentes à classe de interesse (“Gramínea”).

Segundo Tharwat (2021), a métrica F-Measure é uma medida da precisão e o seu valor varia de 0 a 1, sendo que altos valores indicam alto desempenho de classificação. A métrica *F-Measure*, como medida de precisão, indica a qualidade do modelo, sendo uma média harmônica da precisão e *recall*, ou seja, um modelo que apresenta um alto valor de F1-Measure é capaz tanto de acertar suas predições (precisão alta) quanto de recuperar os exemplos da classe de interesse (*recall* alto).

Coeficiente de correlação de Matthews (MCC)

Em nosso trabalho, o valor de MCC foi de 0,895 (Tabela 5), estando mais próximo do valor de referência 1, o que demonstra que a predição em nosso modelo está mais ajustada aos resultados observados.

Segundo Louzada e Ara (2012), o MCC é uma medida de qualidade de duas classificações binárias, sendo utilizada para verificar a classificação geral do modelo e usada mesmo que as classes tenham tamanhos diferentes, sendo interpretada de forma semelhante ao coeficiente de correlação de Pearson, visto que é uma generalização dessa medida (Gorodkin, 2004). Portanto, quanto mais próxima a (1), mais ajustada está a predição aos resultados observados, ou seja, representa uma predição perfeita. Zero (0) indica uma predição mais aleatória e, quando o valor retorna (-1), a interpretação é que se trata de uma predição inversa, ou seja, mostra total discordância entre a classificação feita e a observada pelo supervisor (Vujović, 2021).

- **Área ROC (*Receiver Operating Characteristic*)**

Em nosso modelo, o valor da área ROC foi de 0,989 (Tabela 5), tanto para a classe “Gramínea” como para a classe “Outros”, sendo o valor de AUC ROC de 0,988 (Figura 8). Isso demonstra, segundo Hosmer e Lemeshow (2000), excelente discriminação do modelo e adequação do algoritmo classificador *Random Forest* ao objetivo de segmentar e classificar com precisão a imagem aérea da cobertura vegetal das classes “Gramínea” e “Outros”, separando os respectivos padrões pixels de cada classe com precisão adequada (Tabela 5, Figura 8).

Segundo Hoo et al. (2017), a área sob a curva ROC, também denominada área sob a curva AUC, é uma medida de precisão de um modelo que ajuda na avaliação da sua capacidade de discriminação. Segundo os autores, a curva ROC consiste em uma representação gráfica da performance de um modelo de dados quantitativos segundo sua taxa de sensibilidade (fração dos verdadeiros positivos) e a fração dos falsos positivos (taxa de especificidade). Segundo Miao e Zhu (2020), a curva ROC é uma medida de desempenho do algoritmo classificador que mostra o quão bom o modelo criado pode distinguir entre 0 ou 1, ou positivo e negativo, ou seja, um número que determina quão ajustada é a curva ROC.

Na análise de desempenho do algoritmo classificador, os melhores classificadores têm maior curva para a esquerda no gráfico, ou seja, quanto mais a curva ROC se aproxima do canto superior esquerdo do gráfico, melhor é a qualidade do modelo quanto à capacidade para discriminar grupos ou classes (Polo; Miot, 2020; Tharwat, 2021).

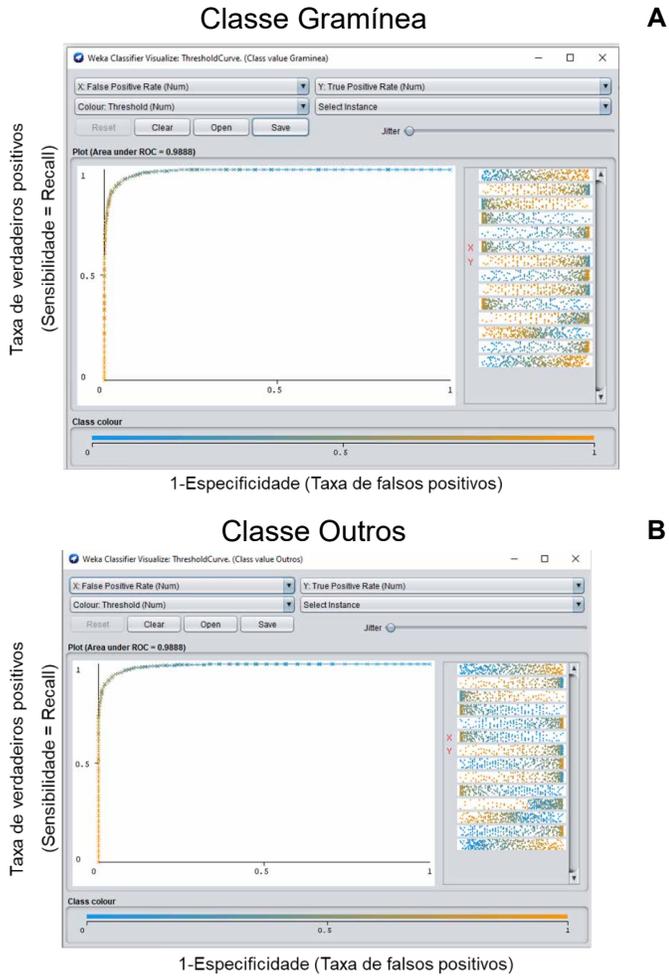


Figura 8. Curva ROC dos resultados segundo sua sensibilidade (taxa de verdadeiros positivos) e especificidade (taxa de falsos positivos), mostrando valor de AUC ROC = 0,9888. Curva ROC foi gerada no software Weka para a classe “Gramínea” (A) e classe “Outros” (B), tendo como algoritmo classificador *Random Forest*.

Área PRC (*Precision-Recall Curve Area*)

Na avaliação do desempenho do nosso modelo treinado, o valor para a área PRC foi de 0,988 para a classe “Gramínea” e de 0,989 para a classe “Outros”, sendo a média de 0,988 (Tabela 5). Esses valores indicam, em termos de interpretação do resultado, excelente capacidade do modelo em

segmentar e classificar corretamente pixels das imagens aéreas da cobertura de gramíneas sobre o solo (Figura 9).

Segundo Miao e Zhu (2020), a curva de precisão-recall representa a precisão da fração de observações com um valor predito positivo que é verdadeiramente positivo (recall x precisão). Segundo os autores, o classificador perfeito terá uma curva de PRC que passa pelo canto superior direito do gráfico, o que corresponde a 100% de precisão. Tharwat (2021) informa que a área PRC é um número que descreve a capacidade do modelo, sendo a melhor capacidade igual a 1,0 e a pior igual a 0,5.

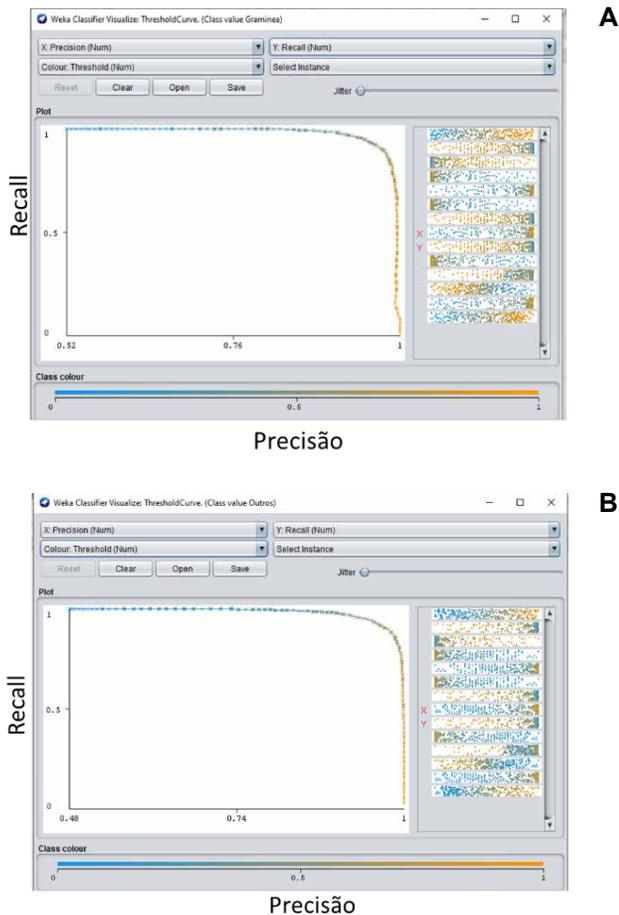


Figura 9. Curva PRC gerada no software Weka para as classes “Gramínea” (A) e “Outros” (B) tendo como algoritmo classificador *Random Forest*.

Desempenho gráfico do modelo e cálculo da estimativa do percentual de cobertura do solo com gramíneas

Como resultado da última etapa da metodologia digital, após treinamento e testes do modelo, o pós-processamento da imagem da subamostra RGB no plugin TWS gerou um gráfico da classificação da imagem da subamostra. Esse resultado gerado foi uma nova imagem binária segmentada e classificada com as cores características de cada classe, sendo a cor verde para a classe “Outros” e a cor vermelha para a classe “Gramínea” (Figura 10). Nessa figura, observa-se o resultado do desempenho gráfico do modelo treinado, constatando-se a excelente precisão no delineamento dos detalhes da cobertura da gramínea sobre o solo na imagem da subamostra segmentada e classificada. Esse desempenho demonstra coerência entre o resultado, o procedimento metodológico digital e as métricas gerais e qualitativas de avaliação do modelo utilizadas.

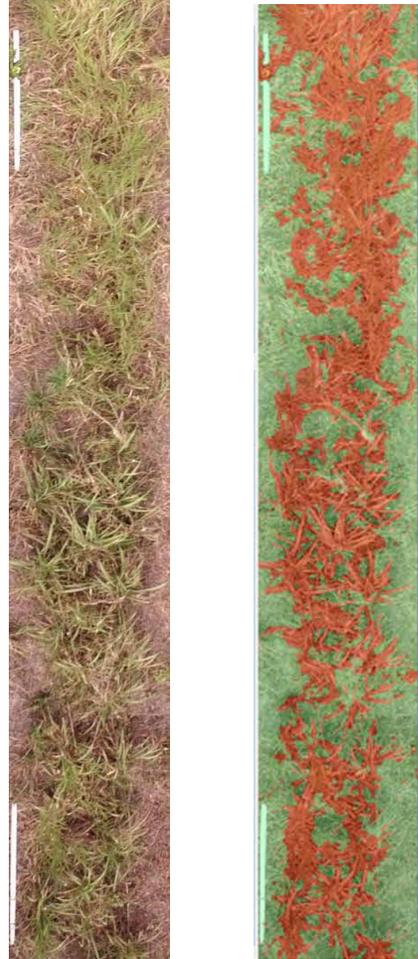


Imagem da subamostra

Imagem segmentada e classificada

Figura 10. Desempenho gráfico do modelo após treinamento supervisionado do algoritmo classificador *Random Forest*, cujo resultado foi obtido a partir do plugin TWS (*Trainable Weka Segmentation*) vinculado ao software Fiji ImageJ.

Na Figura 11, observa-se o resultado final da estimativa do percentual de cobertura do solo com gramíneas *Urochloa* spp. nas entrelinhas de pomar de citros que é gerado automaticamente no software Fiji ImageJ após pós-processamento da imagem da subamostra quando feita a limiarização/binarização da imagem.

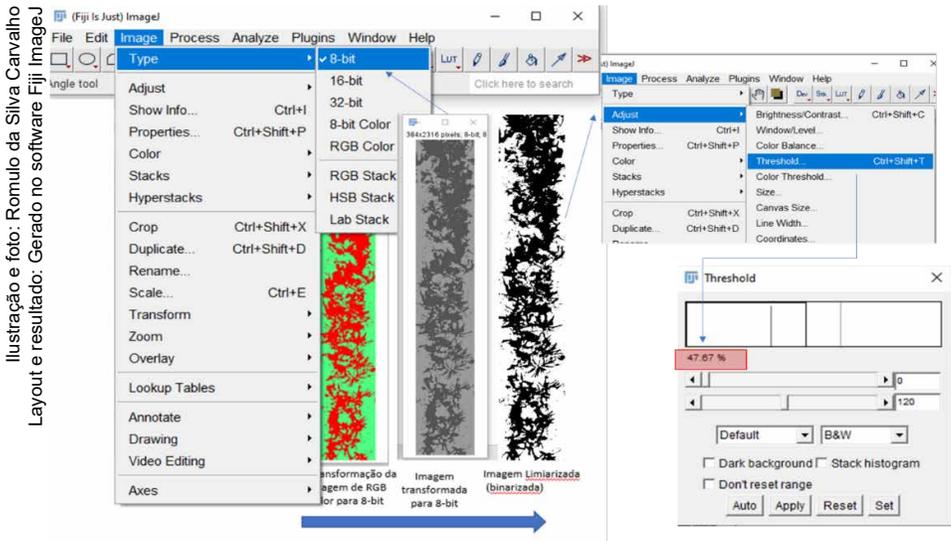


Figura 11. Exemplo de resultado final gerado automaticamente no software Fiji ImageJ da estimativa do percentual de cobertura do solo com gramínea *Urochloa* spp. em pomar de citros, após treinamento supervisionado do algoritmo classificador *Random Forest* a partir do plugin TWS (*Trainable Weka Segmentation*).

Por fim, ressalta-se que esta metodologia digital apresenta custo relativo baixo e resultados precisos por combinar ferramentas de processamento de imagens aéreas de aeronaves remotamente pilotadas (RPA), softwares livres eficientes de código aberto como Fiji ImageJ e Weka, e uso de técnica de inteligência artificial (IA) da subárea de aprendizado de máquina. No entanto, outros custos devem ser considerados pela pesquisa como o investimento inicial para aquisição da aeronave (RPA), treinamento do piloto para obtenção de imagens aéreas dos locais do estudo e a capacitação de pesquisadores no uso de ferramentas modernas de processamento digital de imagens e inteligência artificial.

Conclusões

A presente metodologia digital permite o acompanhamento espacial e temporal da cobertura vegetal de solo com gramíneas *Urochloc* spp., podendo ser utilizada para gerar dados de estimativa do percentual de cobertura de forma a apoiar pesquisas e a tomada de decisão sobre o uso de coberturas vegetais de acordo com o manejo do solo no pomar de citros;

Todas as métricas gerais e qualitativas utilizadas para avaliar a performance do algoritmo classificador *Random Forest* indicaram bom desempenho e adequação do modelo para estimar o percentual de cobertura do solo de gramíneas (*Urochloa* spp.) nas entrelinhas de pomar de citros por meio do uso de imagens aéreas de aeronaves (RPA) em baixa altitude;

Apesar da boa acurácia do modelo (94,73%), houve registro de 5,26% de instâncias classificadas incorretamente, o que demanda atenção do pesquisador (supervisor) para corrigir, sempre que necessário em uma nova imagem de dados numa subamostra, indicando ao algoritmo classificador quais pixels serão efetivamente pertencentes a cada classe, tendo-se como base a experiência técnica do pesquisador e a análise visual das feições da imagem da cobertura e uso do solo;

Pelo fato de a metodologia digital utilizar exclusivamente softwares gratuitos de código aberto, a tecnologia digital se torna de relativo baixo custo para fins de pesquisa científica.

Agradecimentos

Os autores agradecem ao produtor Roberto Shibata proprietário da Fazenda Lagoa do Coco, município de Rio Real, BA, citricultor modelo que ao longo de muitos anos vem contribuindo com a sua parceria diferenciada para o avanço da pesquisa, desenvolvimento e inovação da Embrapa Mandioca e Fruticultura.

Referências

- ADETUNJI, A. T.; NCUBE, B.; MULIDZI, R.; LEWU, F. B. Management impact and benefit of cover crops on soil quality: a review. **Soil & Tillage Research**, v. 204, p. 104717, out. 2020. Disponível em: <https://doi.org/10.1016/j.still.2020.104717>. Acesso em: 12 jan. 2022.
- ALEEN, S.; CAPREZ, L. F.; AHMED, F. Benchmarking machine learning techniques for software defect detection. **International Journal of Software Engineering & Applications (IJSEA)**, v.3) p.1–23, May 2015. Disponível em: <https://arxiv.org/ftp/arxiv/papers/1506/1506.07563.pdf>. Acesso em: 13 jan. 2022.
- ALVES, A. G. C.; COGO, N. P.; LEVIEN, R. Comparação entre os métodos da transeção linear e fotográfico na avaliação de cobertura vegetal morta, sob dois métodos de preparo, após a colheita da soja. **Revista Brasileira de Ciência do Solo, Viçosa**, v. 22, n. 3, p. 491-496, 1998.
- ARGANDA-CARRERAS, I.; KAYNIG, V.; RUEDEN, C.; ELICEIRI, K. W.; SCHINDELIN, J.; CARDONA, A.; SEUNG, H. S. Trainable Weka Segmentation: a machine learning tool for microscopy pixel classification, **Bioinformatics**, v. 33, n. 15, p. 2424–2426, 2017. Disponível em: <https://academic.oup.com/bioinformatics/article/33/15/2424/3092362>. Acesso em: 13 maio 2021.
- BOUCKAERT, R. R.; FRANK, E.; HALL, M.; KIRKBY, R.; REUTEMANN, P.; SEEWALD, A.; SCUSE, D. Weka version 3.9.5. University of Waikato, 2020. Disponível em: <https://www.techspot.com/downloads/7362-weka.html>. Acesso em: 14 jan. 2021
- DENG, L.; MAO, Z.; LI, X.; HU, Z.; DUAN, F.; YAN, Y. UAV-based multispectral remote sensing for precision agriculture: a comparison between different cameras. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.146, p.124-136, 2018. Disponível em: <https://daneshyari.com/article/preview/10139664.pdf>. Acesso em: 13 jan. 2020.
- DIAMANTIDIS, N. A.; KARLIS, D.; GIAKOUMAKIS, E. A. Unsupervised stratification of cross-validation for accuracy estimation. **Artificial Intelligence**, v.116, n.1-2, p.1-16. 2000 Disponível em: <https://www.sciencedirect.com/science/article/pii/S0004370299000946>. Acesso em: 13 jan. 2022.
- DOMINGOS, P. **The master algorithm**: how the quest for the ultimate learning machine will remake our world. Basic Books, 2015.
- GORODKIN, J. Comparing two k-category assignments by a k-category correlation coefficient. **Computational biology and chemistry**, Elsevier, v. 28, n. 5-6, p. 367–374, 2004.
- HAN, Y. J.; HAYES, J.C. 1990a. Soil cover determination by image analysis of textural information. **Transactions of the ASAE**, St. Joseph, v.33, n.2, p.681-686, 1990a.
- HAN, Y. J.; HAYES, J. C. Soil cover determination using color image analysis. **Transactions of the ASAE**, St. Joseph, v.33, n.4, p.1402-1408, 1990b.
- HANLEY, J. A. Receiver operating characteristic (ROC) methodology: the state of the art. **Critical Reviews in Diagnostic Imaging**. 1989, n.29, n.3, p.307-35, 1989. Disponível em: http://www.medicine.mcgill.ca/epidemiology/hanley/reprints/ROC_methodology.pdf. Acesso em: 19 jan. 2022.
- HOSMER, D.W.; LEMESHOW, S. Applied logistic regression. 2nd Edition. New York: John Wiley & Sons, Inc., 2000.
- HOO Z. H., CANDLISH, J.; TEARE, D. What is an ROC curve? **Emergency Medicine Journal**, v. 34, p.357-359, 2017. Disponível em: <https://emj.bmj.com/content/34/6/357>. Acesso em 19 jan. 2022.

JORGE, L. A. C.; CRESTANA, S. 1996a. SIARCS 3.0: Novo aplicativo para análise de imagens digitais aplicados a ciência do solo. In: CONGRESSO LATINO AMERICANO DE CIÊNCIA DO SOLO, 13., 1996a, Águas de Lindóia-SP. **Resumos...** Águas de Lindóia: Sociedade Brasileira de Ciência do Solo, 1996a. 5 p. CD-ROM.

JORGE, L. A. C.; CRESTANA S. **Recomendações práticas para utilização do SIARCS 3.0 nos estudos de raízes, cobertura vegetal, folhas e outras aplicações.** São Carlos, SP: Embrapa Instrumentação Agropecuária, 1996b. (Embrapa Instrumentação Agropecuária. Recomendação Técnica, 4). Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/29877/recomendacoes-praticas-para-utilizacao-do-siarcs-30-nos-estudos-de-raizes-cobertura-vegetal-folhas-e-outras-aplicacoes>. Acesso em: 13 jan. 2022.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data, **Biometrics**, v.33, n.1, p. 159-174, 1977. Disponível em: <https://www.jstor.org/stable/2529310?origin=crossref>. Acesso em: 13 jan. 2022.

LIMA, S. F., TIMOSSI, P. C.; ASSUNÇÃO, H. F. Análise comparativa de técnicas de estimativa de fração de cobertura vegetal por *Urochloa ruziziensis* E *Urochloa* spp. **Planta daninha**, Viçosa, v. 33, n. 3, p. 483-490, 2015. Disponível em: <https://www.scielo.br/j/pd/a/RTgxdTdyCrRTHLSQzQh89Zb/?lang=pt>. Acesso em: 13 jan. 2022.

LOUZADA, F.; ARA, A. Bagging k-dependence probabilistic networks: An alternative powerful fraud detection tool. **Expert Systems with Applications**, Elsevier, v. 39, n. 14, p. 11583–11592, 2012.

MARIANO, D. C. B. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. **BIOINFO - Revista Brasileira de Bioinformática e Biologia Computacional**. 1. ed. Lagoa Santa: Editora Alfabehelix, 2021. v. 1. DOI: 10.51780/978-6-599-275326-01. Disponível em: <https://bioinfo.com.br/metricas-de-avaliacao-em-machine-learning-acuracia-sensibilidade-precisao-especificidade-e-f-score/>. Acesso em: 13 dez. 2021.

MIAO, J.; ZHU, W. Precision-Recall Curve (PRC) classification trees, 2020. Disponível em: https://www.researchgate.net/publication/345970825_Precision-Recall_Curve_PRC_Classification_Trees. Acesso em: 05 jan. 2022.

MITCHELL, Tom. **Machine Learning**. McGraw-Hill, 1997. Disponível em: <https://www.cin.ufpe.br/~cavmj/Machine%20-%20Learning%20-%20Tom%20Mitchell.pdf>. Acesso em: 05 jan. 2022.

MORGAN, J. L.; GERGEL, S. E.; COOPS, N. C. Aerial photography: a rapidly evolving tool for ecological management. **BioScience**, v. 60, n. 01, p. 47-59, 2010. Disponível em: https://www.researchgate.net/publication/240297632_Aerial_Photography_A_Rapidly_Evolving_Tool_for_Ecological_Management. Acesso em: 13/ jan. 2022.

MULLA, D. J. Twenty-Five Years of Remote Sensing in Precision Agriculture: Key Advances and Remaining Knowledge Gaps. **Biosystems Engineering**, v.114, p.358-371, 2013. DOI: <https://doi.org/10.1016/j.biosystemseng.2012.08.009>.

NGOUAJIO, M. et al. Validation of an operator-assisted module to measure weed and crop leaf cover by digital image analysis. **Weed Technology**, Lawrence, v.12, n.3, p.446-453, 1998.

NGOUAJIO, M.; LEMIEUX, C.; LEROUX, G. D. Prediction of corn (*Zea mays*) yield loss from early observations of the relative leaf area and the relative leaf cover of weeds. **Weed Science**, v.47, n.3, p.297-304, 1999.

PESSI, D. D.; BELIN, R. B.; JUNIOR, P. L. M.; SILVA, N. M. Aeronaves remotamente pilotadas e suas aplicações no manejo agrícola e ambiental. **Cadernos de Ciência & Tecnologia**, v. 37, n. 2, e26605, 2020. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/219905/1/26605-127846-5-PB.pdf>. Acesso em: 13 jan.2022.

RIEGLER-NURSCHER, P.; PRANKL, J.; Bauer, T.; STRAUSS, P.; PRANKL, H. A machine learning approach for pixel wise classification of residue and vegetation cover under field conditions. **Biosystems Engineering**, v. 169, p. 188-198, 2018. Disponível em: https://www.researchgate.net/profile/Peter-Strauss-2/publication/323884521_A_machine_learning_approach_for_pixel_wise_classification_of_residue_and_vegetation_cover_under_field_conditions/links/5ab177ce0f7e9b4897c39d79/A-machine-learning-approach-for-pixel-wise-classification-of-residue-and-vegetation-cover-under-field-conditions.pdf. Acesso em: 13 jan. 2022.

RIZZARDI, M. A.; FLECK, N. G. Métodos de quantificação da cobertura foliar da infestação de plantas daninhas e da cultura da soja. **Ciência Rural**, v. 34, n. 1, p. 13-18, 2004. Disponível em: <https://www.scielo.br/j/cr/a/7ccngNW3dhdzk4ZNHDnKhDm/abstract/?lang=pt>. Acesso em: 13 jan. 2022.

RUEDEN, C.T.; SCHINDELIN, J.; HINER, M.C.; DEZONIA, B. E.; WALTER, A. E.; ARENA, E.T.; ELICEIRI, K. W. ImageJ2: ImageJ for the next generation of scientific image data. **BMC Bioinformática**, v.18, 529, 2017. Disponível em: <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-017-1934-z>. Acesso em 13 jan. 2022.

SANTOS, E. L.; CECCATTO, S. EL K.; PENHA, G. G.; ALMEIDA, N. B.; DE ALMEIDA, L. F. DE A. . Imagens aéreas na avaliação da qualidade da cobertura conforme o manejo do solo. **Acta Iguazu**. v.9. p.33-44, 2020. Disponível em: https://www.researchgate.net/publication/343267933_Imagens_aereas_na_avaliacao_da_qualidade_da_cobertura_conforme_o_manejo_do_solo. Acesso em: 13 jan. 2022.

SCHINDELIN, J.; ARGANDA-CARRERAS, I.; FRISE, E.; KAYNIG, V.; LONGAIR, M.; PIETZSCH, T.; PREIBISCH, S.; RUEDEN, C.; SAALFELD, S.; SCHMID, B.; JEAN-YVES TINEVEZ, J-Y.; WHITE, D. J.; HARTENSTEIN, V.; ELICEIRI, K.; TOMANCAK, P.; CARDONA, A. 2019. Fiji: an open-source platform for biological-image analysis. **Nature Methods**. 2012 v9: p.676-682. Disponível em: <https://www.nature.com/articles/nmeth.2019>. <https://doi.org/10.1038/nmeth.2019>. Acesso em: 12 jan. /2022.

SLONEKER, L. L.; MOLDENHAUER, W. C. Measuring the amounts of crop residue remain in gafterillage. **Journal of Soil and Water Conservation**, v. 32, p.231-236, 1977.

SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, F-score and ROC: A Family of Discriminant Measures for Performance Evaluation, in: AUSTRALASIAN JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, Springer, p. 1015–1021, 2006. Disponível em: <https://www.aaai.org/Papers/Workshops/2006/WS-06-06/WS06-06-006.pdf>. Acesso em: 13 jan. 2022.

THARWAT, A. . «Classification assessment methods». **Applied Computing and Informatics**, v.17, n.1, p.168-192, 2021. Disponível em: <https://www.emerald.com/insight/content/doi/10.1016/j.aci.2018.08.003/full/html>. Acesso em: 13 jan. 2022.

TRIAS-SANZ, R.; STAMON, G.; LOUCHET, J. Using colour, texture, and hierarchial segmentation for high-resolution remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 63, n. 2, p. 156-168, 2008. Disponível em: http://jean.louchet.free.fr/publis/Trias-colour_2008.pdf. Acesso em: 13 jan. 2022.

VANDENBROUCKE, N.; MACAIRE, L.; POSTAIRE, J.-G. Color image segmentation by pixel classification in an adapted hybrid color space. Application to soccer image analysis. **Computer Vision and Image Understanding**, v. 90, Issue 2, 2003. P. 190-16. DOI: [https://doi.org/10.1016/S1077-3142\(03\)00025-0](https://doi.org/10.1016/S1077-3142(03)00025-0).

VARELLA, C.v.A.v.A.; PINTO, F.A.C.; QUEIROZ, D.v.M.; SENA JÚNIOR, D. G. Determinação da cobertura do solo por análise de imagens e redes neurais. **Revista Brasileira de Engenharia**

Agrícola e Ambiental, Campina Grande, v.6, n.2, p.225-9, 2002. Disponível em: https://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662002000200007&lng=pt&nrm=iso. Acesso em: 03 maio 2021.

VUJOVIĆ, Z. D. Classification Model Evaluation Metrics. (IJACSA) **International Journal of Advanced Computer Science and Applications**, v.12, n. 6, 2021. Disponível em: https://thesai.org/Downloads/Volume12No6/Paper_70-Classification_Model_Evaluation_Metrics.pdf . Acesso em: 13 jan. 2022.

XIE, Y., SHA, Z., YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v.1, n.1, p. 9–23, 2008. Disponível em: <https://academic.oup.com/jpe/article/1/1/9/1132900>. Acesso em: 13 jan. 2022.

YANG, J.; HE, Y.; CASPERSEN, J.; JONES, T. A discrepancy measure for segmentation evaluation from the perspective of object recognition. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 101, n. 1, p. 186-192, 2015. Disponível em: https://tspace.library.utoronto.ca/bitstream/1807/108167/4/A_discrepancy_measure_2015_TSpace.pdf. Acesso em: 13 jan.2022.



Mandioca e Fruticultura

MINISTÉRIO DA
AGRICULTURA, PECUÁRIA
E ABASTECIMENTO

