Delimitação automática da aveia preta (*Avena strigosa*) utilizando-se de softwares com código aberto e de imagens obtidas pelo processamento de fotos captadas por RPA (Drone)

Ricardo Kwiatkowski Silva – Universidade Estadual de Ponta Grossa – UEPG – ricardokds@gmail.com
Luís Miguel Schiebelbein – Universidade Estadual de Ponta Grossa – UEPG – lmschiebelbein@uepg.br
Neyde Fabiola Balarezo Giarola – Universidade Estadual de Ponta Grossa – UEPG – neydef@uepg.br
Eduardo Augusto Agnellos Barbosa – Universidade Estadual de Ponta Grossa – UEPG – eaabarbosa@uepg.br
Fabrício Tondello Barbosa – Universidade Estadual de Ponta Grossa – UEPG – fabriciotondello@gmail.com

Resumo: Utilizando-se de uma Aeronave Remotamente Pilotada (RPA), popularmente conhecida como Drone, podemos obter dados de alta resolução temporal de uma área agrícola. Dessa forma, a elaboração de metodologias aplicadas ao mapeamento automático traz benefícios como a geração mais rápida de informações sobre o desenvolvimento de uma determinada cultura. No âmbito das técnicas de reconhecimento automático de feições, temos a análise de imagem baseada em objetos geográficos (Geographic Object-Based Image Analysis - GEOBIA), destinada ao desenvolvimento de métodos automatizados para particionar imagens em objetos significativos e avaliar suas características, gerando automaticamente novas informações espaciais. Para o particionamento e classificação de imagens, temos algoritmos de segmentação e classificadores com código aberto implementados por meio do Orfeo ToolBox (OTB) no software QGIS. Este trabalho utilizou-se de algoritmos de particionamento e classificação existentes no software supracitado e de imagens resultantes do processamento de fotos obtidas a partir de uma câmera de pequeno formato embarcada em uma RPA. A metodologia elaborada foi eficaz em delimitar a aveia-preta em estádio inicial de desenvolvimento e os modelos de predição que geraram os melhores resultados foram os que utilizaram o algoritmo supervisionado de aprendizado de máquina *Support Vector Machine* (Máquina de Vetores de Suporte – SVM). O procedimento elaborado pode oferecer suporte ao mapeamento automático de outras culturas.

Palavras-chave: QGIS, R/Rstudio, Mapeamento automático, Aveia.

Automatic delimitation of black oat (Avena strigosa) using open-source software and images processed from photos captured by RPA (Drone)

Abstract: *Using a Remotely Piloted Aircraft (RPA), commonly known as a drone, we can obtain high temporal resolution data of an agricultural area. This way, developing methodologies for automatic mapping provides benefits such as faster generation of information about the development of a specific crop. In the realm of automatic feature recognition techniques, we have Geographic Object-Based Image Analysis (GEOBIA), which is aimed at developing automated methods to partition images into meaningful objects and assess their characteristics, generating new spatial information automatically. For image partitioning and classification, there are segmentation algorithms and open-source classifiers implemented through the Orfeo ToolBox (OTB) in QGIS software. This study utilized partitioning and classification algorithms available in the aforementioned software and images resulting from processing photos taken by a small-format camera mounted on an RPA. The developed methodology was effective in delineating black oat in the early stages of development, and the prediction models that produced the best results were those using the supervised machine learning algorithm Support Vector Machine (SVM). The developed procedure could support the automatic mapping of other crops.*

Key-words: *QGIS, R/Rstudio, Automatic mapping, Oat.*

1. Introdução

Conforme Hay e Castilla (2008), a análise de imagem baseada em objetos geográficos (Geographic Object-Based Image Analysis - GEOBIA) é uma subdisciplina da Ciência da Informação Geográfica, destinada ao desenvolvimento de métodos automatizados para particionar imagens em objetos significativos e avaliar suas características por meio de escalas espaciais, espectrais e temporais, de modo a gerar informações espaciais. De acordo com Morin *et al*. (2024) apud Chen *et al*. (2018), a segmentação, aplicada a GEOBIA, refere-se a divisão da imagem em diferentes regiões homogêneas, baseando-se em características radiométricas. Para o particionamento de imagens com radiometria de até 8 bits, tem-se algoritmos

com código aberto implementados por meio do *Orfeo ToolBox* (OTB) no *software QGIS* (GRIZONNET *et al*, 2017). Em trabalho correlato, Ye *et al*. (2023), avaliaram a capacidade de detecção de uma cultura por meio da extração de vetores promovida pelo algoritmo de agrupamento *Mean-Shift*. Os autores supracitado usaram imagens obtidas a partir de algoritmo SfM-MVS (*Structure from Motion - Multi-View Stereo*) para reconstrução tridimensional, aplicado a 378 imagens obtidas por RPA. A acurácia dos modelos de classificação pode ser verificada mediante matriz de confusão. Angelini *et al*. (2023), descrevem o resultado desta análise como a matriz quadrada onde os elementos diagonais indicam o número de amostras classificadas corretamente e os demais elementos, fora da diagonal, referem-se a erros de omissão ou comissão. Bento *et al*. (2023), valendo-se da linguaguem R, avaliaram a identificação de plantas daninhas com modelos utilizando os algoritmos supervisionados de aprendizado de máquina *Support vector machine* (Máquina de Vetores de suporte – SVM) e *Random forest* (Floresta Aleatória – RF), aplicados a imagens obtidas por RPA. O presente trabalho utiliza-se de um ortomosaico nos comprimentos de onda do visível elaborado a partir de fotos captadas por RPA com uma câmera de pequeno formato e da análise GEOBIA. O estudo tem por objetivo estabelecer uma metodologia para delimitar automaticamente a aveia preta em estádio inicial de desenvolvimento, utilizando-se de algoritmos com código aberto.

2. Material e Métodos

2.1 Área de Estudo

Megaparcelas do projeto NAPI Prosolo. Descreve-se a área experimental como locais delimitados em áreas agrícolas com aproximadamente dois hectares cada e instalados aos pares (uma com terraços e outra sem), objetivando coletar dados sobre processos erosivos, subsidiando assim estudos científicos. Insere-se a aveia preta na área experimental como uma das culturas de rotação no processo de proteção do solo.

2.2 Obtenção do ortomosaico

O plano de voo para levantamento das fotos foi elaborado em software livre compatível com a RPA DJI Mavic 2 Pro para a altura de 80 metros e sobreposições longitudinal de 80% e lateral de 70%. Seguiu-se o processamento do ortomosaico com 09 pontos de controle. Por meio destes avaliou-se a precisão planimétrica do ortomosaico utilizando-se do cálculo da raiz do erro médio quadrático (*Root Mean Square Error* - RMSE).

2.3 GEOBIA

Utilizando-se do *software* QGIS, seis recortes do ortomosaico foram obtidos para aplicação da técnica *Segmentation* do *plugin OTB*, utilizando-se da técnica de agrupamento *Mean-Shift*. Partindo-se das camadas vetoriais geradas pelo segmentador, extraiu-se a estatística radiométrica das imagens conforme um dado polígono por meio da ferramenta *Zonal Statistics*. Calculou-se assim a média, desvio padrão, valor mínimo e valor máximo.

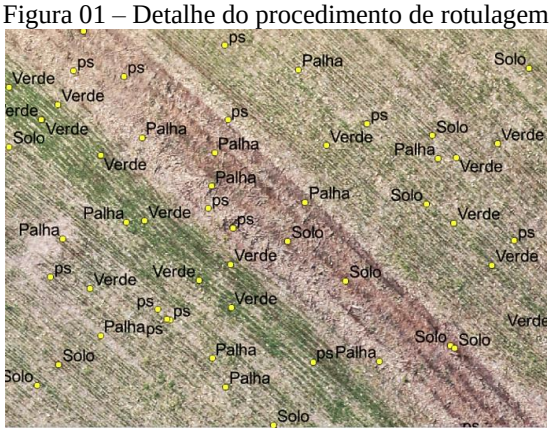
Para geração dos modelos de treinamento foram rotuladas qualitativamente 120 amostras por recorte (30 para cada classe) totalizando 720 pontos. Apresenta-se no quadro 01 a chave de classificação para posterior predição da cobertura do solo e na figura 01 o procedimento de rotulagem em detalhe.

Quadro 01 – Chave de amostragem para predição

Identificador (id)	Cobertura do solo no recorte
1	Palha
2	ps (Palha / Solo)
3	Solo
4	Verde (Aveia Preta)

Fonte: Os autores

Figura 01 – Detalhe do procedimento de rotulagem



Fonte: Os autores

Segue-se a união entre a camada com os rótulos e a camada vetorial que possui as estatísticas radiométricas, por meio da ferramenta *Join*. A partir deste arquivo gera-se os modelos com os classificadores KNN, RF SVM, por meio da

ferramenta *TrainVectorClassifier*. Utilizando-se da técnica *VectorClassifier* o arquivo segmentado com as estatísticas é submetido a um determinado modelo de treinamento. O resultado é convertido para o formato .xlsx que detem o rótulo e a informação quantitativa (predita pelo classificador) para avaliação por meio da linguagem *R* (R CORE TEAM, 2022). Gerou-se assim, as matrizes de confusão e as estatísticas para validação da acurácia dos modelos.

O processamento da GEOBIA foi executado em separado para o recorte 2T, realizando-se uma avaliação qualiquantitativa. Com base em *n* testes realizados utilizando-se da metodologia descrita foi elaborado o diagrama de fluxo de dados da GEOBIA por meio do *software* QGIS, aplicado a imagens obtidas a partir de uma câmera de pequeno formato embarcada em uma RPA.

3. Resultados e Discussões

Foram obtidas 384 fotos aéreas que resultaram no ortomosaico controlado com resolução espacial de 2,0 cm e precisão planimétrica radial (RMSEr) igual a 0,03 metros. Apresenta-se na figura 02 o ortomosaico e os polígonos retangulares para recorte das imagens (numerados de 1 a 3) conforme sua localização nas Megaparcelas (com Terraços com a sigla T e Sem Terraços com a sigla ST). Os 720 pontos representados na cor amarela referem-se as amostras rotuladas qualitativamente para validação, conforme a chave de uso do solo.

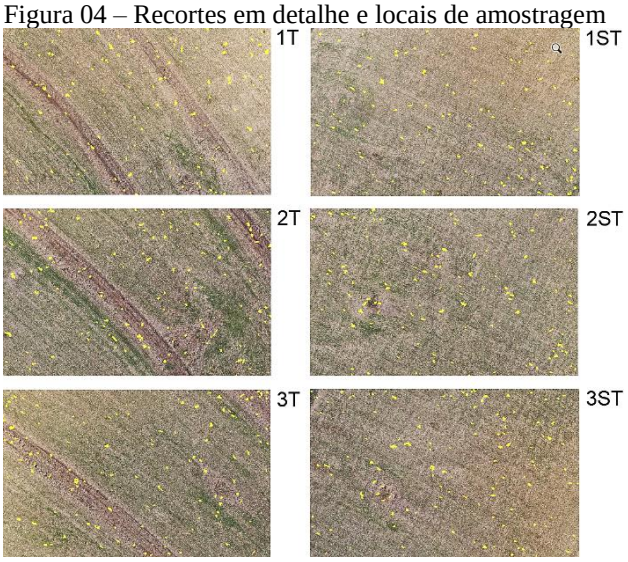
Figura 03 – Ortomosaico, vetores para recorte e pontos de amostragem (na cor amarela)



Fonte: Os autores

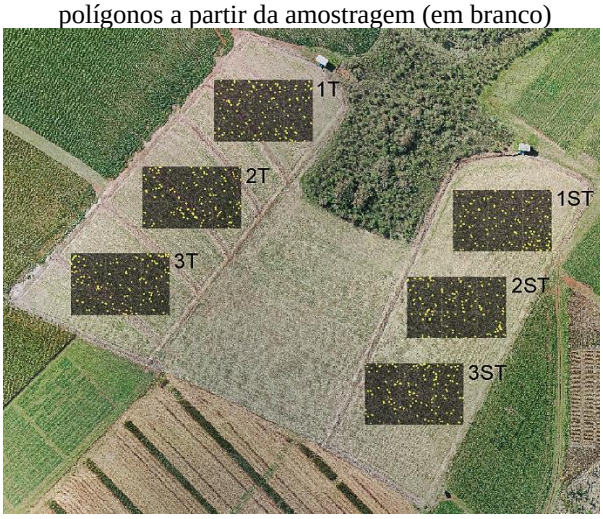
A figura 04 demonstra em detalhe os recortes utilizados no processo de segmentação.

Figura 04 – Recortes em detalhe e locais de amostragem



Na figura 05 demonstra-se sobre o ortomosaico os polígonos resultantes do procedimento de segmentação computado conforme os recortes demonstrados em detalhe na figura 04. Os poligonos selecionados para teste correspondem em localiação aos pontos de rotulagem previamente estabelecidos. Por meio destes realizou-se a estatística zonal utilizada para avaliação dos classificadores.

Figura 05 – Resultado da segmentação e seleção de polígonos a partir da amostragem (em branco)



Fonte: Os autores

Avaliou-se os classificadores KNN, RF e SVM quando aplicados ao processo de segmentação Mean-Shift por meio do cálculo das matrizes de confusão e dos valores de acurácia (proporção do uso do solo predito corretamente), Sensibilidade (poder do modelo em classificar acertivamente uma dada classe) e Especificidade (poder do modelo em negar a predição de uma dada classe). Apresenta-se na

tabela 01 os resultados obtidos na comparação entre os modelos quando aplicados simultâneamente aos seis recortes.

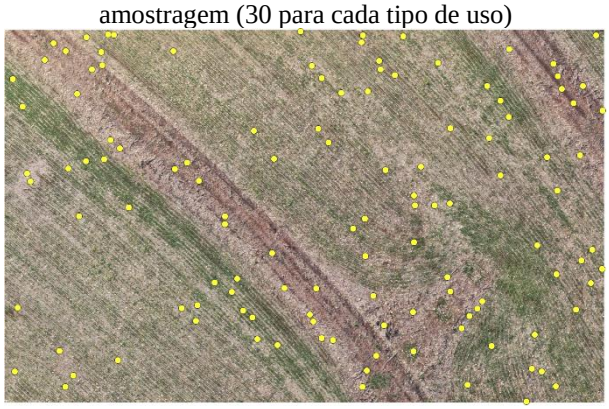
Tabela 01 – Avaliação dos classificadores para os seis recortes (120 amostras para cada classe)

	KNN	RF	SVM
Acurácia	0,8653	0,9278	0,9333
Sensibil. palha	0,8667	0,9222	0,8667
Sensibil. palha/solo	0,9500	0,9833	0,9889
Sensibil. solo	0,7389	0,8667	0,8889
Sensibil. aveia	0,9056	0,9389	0,9889
Especif. palha	0,9222	0,9611	0,9685
Especif. palha/solo	0,9630	0,9759	0,9907
Especif. solo	0,9463	0,9722	0,9556
Especif. aveia	0,9889	0,9944	0,9963

Fonte: Os autores

Verifica-se a partir dos resultados gerados por meio do código na linguagem R que o classificador que apresentou o melhor resultado no processo de predição das quatro classes foi o SVM (Acurácia 0,9333). O classificador supracitado também apresentou o maior Sensibilidade (0,9889) e Especificidade (0,9963) na classificação aveia preta.
Por meio do recorte 2T (figura 06) e utilizando-se de 120 amostras (30 para cada classe), realizou-se a avaliação qualiquantitativa.

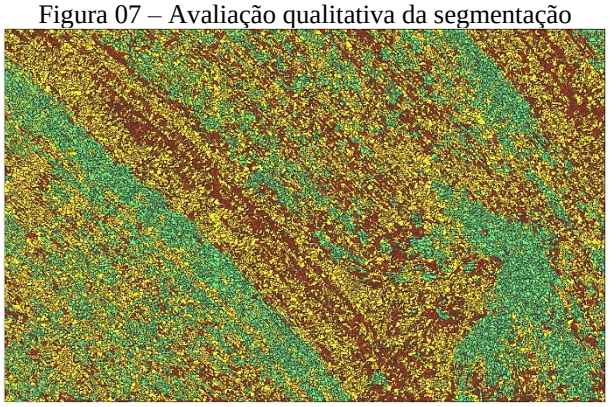
Figura 06 – Recorte do ortomosaico (2T) e pontos de amostragem (30 para cada tipo de uso)



Fonte: Os autores

Executando-se novamente o procedimento de segmentação ao recorte 2T seguido da avaliação da matriz de confusão para comparação dos modelos, obteve-se os resultados demonstrados na figura 07 (resultado qualitativo) e na tabela 02 (resultado quantitativo).

Figura 07 – Avaliação qualitativa da segmentação



Fonte: Os autores

Na imagem temática representada na figura 07 a cor verde representa a aveia preta, a cor marrom a superfície do solo e os tons de amarelo a palha ou palha-solo.

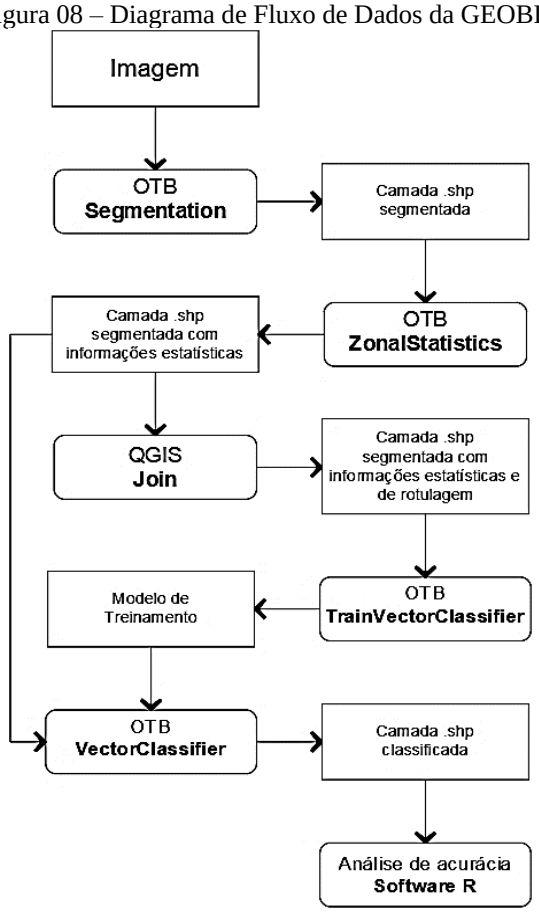
Tabela 02 – Avaliação dos classificadores para o recorte 2T (30 amostras para cada classe)

	KNN	RF	SVM
Acurácia (2T)	0,7250	0,950	0,9667
Sensibil. palha	0,7330	0,9667	0,9333
Sensibil. palha/solo	0,5333	0,9667	1,0000
Sensibil. solo	0,7000	0,9667	0,9333
Sensibil. aveia	0,9333	0,9000	1,0000
Especif. palha	0,9111	0,9889	0,9778
Especif. palha/solo	0,9667	0,9667	1,0000
Especif. solo	0,9111	0,9889	0,9778
Especif. aveia	0,8444	0,9889	1,0000

Fonte: Os autores

No procedimento quantitativo (recorte 2T) verificou-se novamente que o classificador KNN apresentou acurácia inferior (0,7250). E que o modelo que utilizou-se do classificador SVM apresentou maior acurácia, Sensibilidade e Especificidade em predizer a aveia preta.
Demonstra-se na figura 08 o diagrama de fluxo de dados da metodologia elaborada. Retângulos com bordas arredondadas correspondem a transformações e setas indicam os movimentos dos dados entre funções. Retângulos representam repositórios de dados gerados para o processamento subsequente.

Figura 08 – Diagrama de Fluxo de Dados da GEOBIA



Fonte: Os autores

4. Conclusões

Verifica-se qualitativamente por meio da figura 07 que a segmentação individualizou a aveia preta, demonstrando onde esta se desenvolveu e onde o solo e a palha ainda são visíveis. A comparação entre os rótulos inseridos qualitativamente com os valores preditos via matriz de confusão apresentaram melhores resultados de acurácia respectivamente para os modelos gerados com os classificadores SVM e RF. Além de elevadas taxas de acerto na classificação, os modelos que utilizaram-se do SVM apresentaram maior Sensibilidade e Especificidade, aproximando-se ou igualando-se a 1 em alguns casos. O modelo que apresentou menor capacidade de prever os resultados da classificação foi o KNN, com os menores valores de acurácia, corroborados pelos valores da estatística Kappa. As variáveis estátisticas calculadas na Estatística Zonal foram suficientes para que os classificadores apresentassem bons resultados de acurácia.

Agradecimentos

A Fundação Araucária e ao Serviço Nacional de Aprendizagem Rural (SENAR) pelo apoio financeiro ao projeto Napi Prosolo. A Universidade Estadual de Ponta Grossa (UEPG) e ao Programa de Pós-Graduação em Agronomia (MESAGRO - UEPG).

Referências

ANGELINI, R. *et al*. A review and test of shoreline extraction techniques. In: **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Padua, Italy, 2023: ISPRS Archives, v. XLVIII-1/W1, p. 16-24.

BENTO, N. L. *et al*. Weed Detection and Mapping of a Coffee Farm by a Remotely Piloted Aircraft System. **Agronomy**. v. 13, n. 830, 2023.

CHEN, G. *et al*. Geographic object-based image analysis (GEOBIA): emerging trends and future opportunities. **GIScience & Remote Sensing**. Taylor & Francis, v. 55, n. 2, p. 159-182, 2018.

GRIZONNET, G. J. *et al*. Orfeo ToolBox: open source processing of remote sensing. **Open Geospatial Data, Software and Standard**. Springer, v. 2, p. 15, 2017.

HAY, G. J.; CASTILLA G. **Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline**. Springer, Heidelberg, Berlin, New York, p. 75-89, 2008.

MORIN, E. *et al*. Mapping past land cover on Poitiers in 1993 at very high resolution using GEOBIA approach and open data. **Data in Brief**. Elsevier, v. 52, n. 109829, 2024.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**. Vienna, Austria, 2022.

YE, Z. *et al*. A comparison between Pixel-based deep learning and Object-based image analysis (OBIA) for individual detection of cabbage plants based on UAV Visible-light images. **Computers and Eletronics in Agriculture**. v. 209, p. 107822-107836, 2023.