

CLASSIFICAÇÃO DE ORTOFOTO COM O USO DE *OPEN SOURCE* EM *MACHINE LEARNING* NA PRAIA DE FIGUEIRA DA FOZ – PORTUGAL

Hanna Aimée Gonçalves¹

Diogo Duarte²

Gustavo Mota de Sousa³

1. Universidade Federal Rural do Rio de Janeiro - Departamento de Engenharia - BR 465 km 07 s/n, Seropédica, Rio de Janeiro, Brasil(hannaimeefg@hotmail.com)

2. Universidade de Coimbra - Departamento de Matemática-Apartado 3008, EC Santa Cruz, 3001-501, Coimbra, Portugal(diogovad@gmail.com)

3. Universidade Federal Rural do Rio de Janeiro - Departamento de Geografia - BR 465 km 07 s/n, Seropédica, Rio de Janeiro, Brasil (gustavobond@gmail.com)

ABSTRACT

This study focuses on class identification, with great attention to vegetation, on the beach of Figueira da Foz - Portugal. To form this activity, images derived from the drone Matrice 600 were used, through "open source", specifically Orfeo Toolbox, such complement was developed with the aid of the free software QGIS. The trainer Randon Florest was used and as resource extraction of the types Haralick, Morphological Operation in Gray Scale and Radiometric Indices. Having as original data in their sets the classes of vegetation, sand and water, both for training, testing and validation according to the Permanent Validation technique. Using statistical methods, the fusion matrix was obtained in each image, generating the pixel occupied by area of each sample and class, thus obtaining its accuracy, precision, evocation and F1 score. After analyzing the resolution proportional to the spatial resolution of the base images, it was concluded that the orthophoto resulted in a future accuracy of 94%. In summary, this study sought to point out the relationship between data collection, its treatment, analysis and sharing, taking into account Machine Learning techniques with different forms and results of reach, both with regard to the influence of geospatial information on society, regarding the performance of this Science, which is applicable today.

Keywords: Drone; Open source; Classification; Machine learning

INTRODUÇÃO

Em busca de identificação para as classes vigente na localidade da Praia de Figueira a Foz – Portugal, teve-se a aplicabilidade dos métodos de classificação de imagens, derivada do VANT, empregada por intermédio do *software* QGIS, onde ocorre a incorporação com recursos de algoritmos em código aberto. E, por meio deste objetivo, foi possível extrair recursos métricos para a análise de qualidade da classificação dos gêneros existentes na região então estudada.

É notório o uso crescente de tecnologias para a obtenção de dados geoespaciais e com finalidades diversas, as redes de aplicações da Ciência Espacial tende a expandir-se possibilitando a resolução de desafios com soluções otimizadas.

Como possibilidade de obtenção dos dados geoespaciais, pode-se constar plataformas como, os satélites e Veículos Aéreos Não Tripulados (VANT), aviões, lasers terrestres, dentre outras ferramentas tecnológicas. E no que se diz respeito aos VANT, são tecnologias com alto valor contribuinte de dados e informações geoespaciais com consideráveis precisões, no qual, têm-se mobilidade mais flexível a obtenção de tais dados. Logo, são possíveis vantagens do sensoriamento remoto por VANT em relação ao aerotransportado por aeronaves tripuladas e ao orbital, podendo ser: a redução dos custos de obtenção de imagens/fotografia aéreas; maior flexibilidade de resolução temporal para aquisição de imagens e alta resolução espacial; possibilidade de execução de missões em condições adversas sem risco de vida para o piloto e operador da câmara aerofotogramétrica; menor necessidade e gastos de treinamento de pilotos e; maior facilidade e velocidade de incorporação de novas tecnologias (LONGHITANO, 2010).

No entanto, há uma série de fatores que podem interferir no processo de classificação dos alvos presentes na imagem. Pois, a classificação de imagens deve ser vista como um processo estatístico e probabilístico que tenta ao máximo aproximar o mapa digital à realidade. O resultado da classificação deve ser avaliado com base no desempenho do classificador proposto e validado por critérios numéricos para estimar a precisão e a sua acurácia (MENESES; ALMEIDA, 2012).

METODOLOGIA

O presente trabalho adotou-se como área de estudo (Figura 1) a região da Cidade de Figueira da Foz, sendo a mesma presente no distrito de Coimbra, localizada na província da Beira Litoral, Coimbra – Portugal.

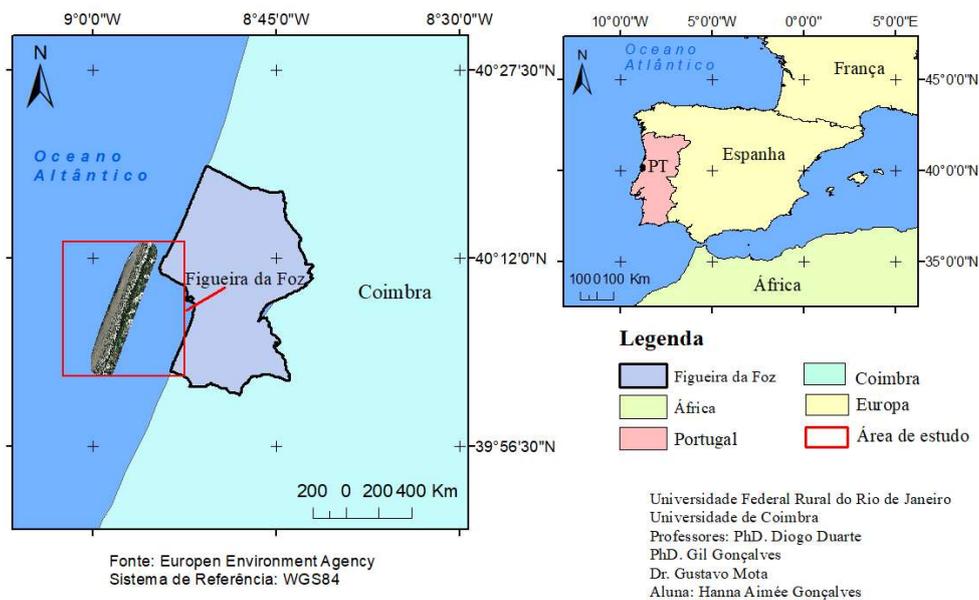


Figura 1. Mapa de localização da área de estudo.

Posteriormente, sucedeu-se a investigação do campo de estudo no dia 02 de outubro de 2019, em que, utilizou-se um veículo aéreo não tripulado (VANT) do modelo Matrice 600 pro, desenvolvido pela empresa chinesa DJI (*Dà-JiāngInnovations*). Veículo este, que contém de forma embarcada o *RTK (Real Time Kinematic)*, técnica de posicionamento e navegação GNSS, proporcionando a localização em tempo real. Além disto, é composto por câmera multiespectral, carregamento de até seis baterias simultâneas gerando tempo de voo estendido, sistema multi-rotor o que permite mais estabilidade, rendimento e voos precisos.

Com o levantamento, foi realizado o processamento, por meio do Software Pix4D, tendo a licença pertencente a Universidade de Coimbra, com tal ação, obteve-se: 604 imagens da Região; Área de 55.1984 hectares; GSD (*Average Ground Sampling Distance*) de 3.35 centímetros; E o RMS Error (*Root Mean Square Error*) de aproximadamente: X= 1.42 metros; Y= 1.38 metros; Z=0.36 metros.

No que se refere sobre a posição otimizada das coordenadas de entrada das imagens, levando em consideração de que este erro é a diferença entre a geolocalização inicial da câmera e as posições calculadas, encontrou-se uma média de erro de aproximadamente 0.046 % em X; 0.004 % em Y; 0.01 % em Z.

Para mais, foram produzidos o modelo digital de superfície (MDS) e respectivo ortofoto, , ambos a localidade. Tal ortofoto é composta por quatro bandas, sendo RGB (Red, Green, Blue) e o NIR (infravermelho próximo), isto é, canais presentes na câmera multiespectral. É importante relatar que diante do fato das câmeras multiespectrais possuírem múltiplos sensores, sua captação de imagens conta com diferentes

frequências de onda ao mesmo tempo, pois registra tanto as ondas do espectro visível (RGB) ao infravermelho (NIR). Com isso, adotou-se a organização dos conjuntos de dados, também chamada de *resampling*, visando eficiente aprendizagem do algoritmo *open source*.

As principais técnicas de *resampling* são: *Hold-out validation*; *Bootstrap*; *Cross validation*. E dentre essas, foi escolhido *Hold-out validation*, pois foram consideradas três divisões no conjunto de dados, sendo: treinamento e validação, ambos utilizados na construção do modelo; E o teste, usado para medir e analisar o desempenho do modelo construído.

Então, sucedeu-se a divisão entre as amostras em três classes: 1 - Vegetação; 2 – Areia/Solo exposto; 3 – Água. Sendo as parcelas ilustradas na Tabela 1 e Figura 2 abaixo:

TABELA 1. CLASSES

Conjuntos	Vegetação	Areia	Água	Total:
Treinamento	100	55	34	189
Validação	50	30	21	101
Teste	73	59	30	162
Total:	223	144	85	452

Fonte: Autora.

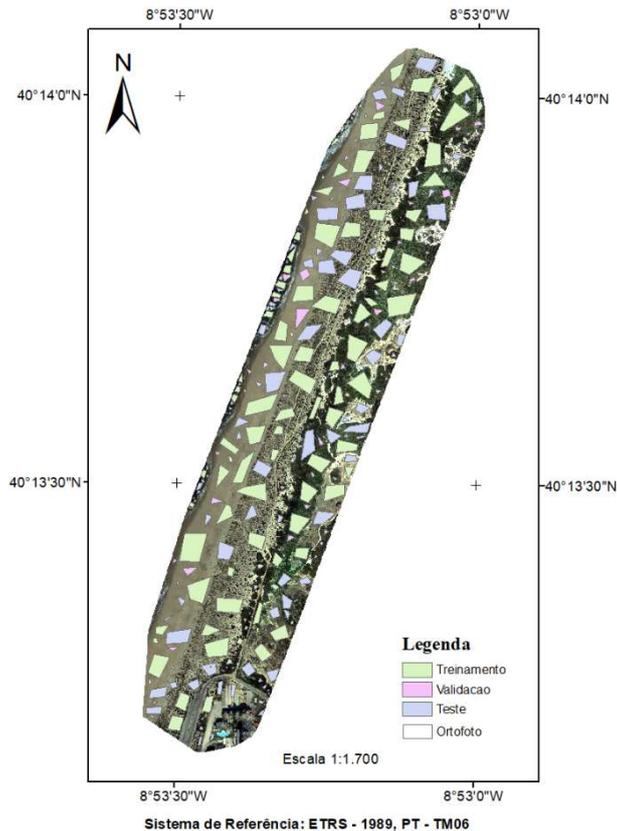


Figura 2. Amostras – Drone

Em princípio ocorreu o processamento da ortofoto, como expressado antes, composta por quatro bandas, desta imagem foram extraídos recursos com intuito da composição de bandas para ampliar o campo de retirada de informações. Para este estudo em específico, foram escolhidos três padrões, sendo: *Haralick* Simples, *Gray ScaleMorphologicalOperation* (GSMO) e *RadiometricIndices*. Depois, no âmbito desse trabalho, aplicou-se duas saídas, *NDVI* (*NormalizedVegetation Index*) e *NDWI* (*NormalizedDifferenceWater Index*).

Seguidamente, ocorreu o empilhamento das bandas, através da ferramenta *Merge*, gerando então três imagens com quantidades de bandas diferentes e superiores quando comparada a da ortofoto, Figura 2.

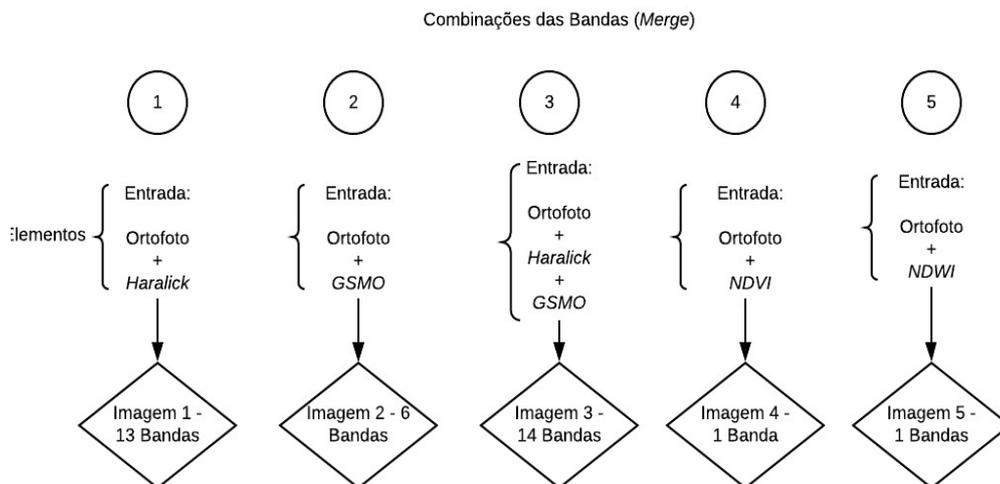


Figura 2. Composição das Bandas – Drone.

Para o treinamento das classes extraídas no trabalho científico, decidiu-se utilizar o classificador *Random Florest* (RF), diante do fato de que, “é um algoritmo de *Machine Learning* amplamente usado consistindo em um conjunto de árvores de decisão. Utilizando agregação de *bootstrap*, ou seja, ensacamento, para criar diferentes subconjuntos de treinamento para produzir uma diversidade de árvores, cada uma fornecendo um resultado de classificação para as amostras não escolhidas.

Deste modo, foram processados a classificação de todas as imagens geradas, em cada caso, utilizou-se como vetor de entrada o treinamento e como vetor de validação, os dados de validação, proporcionando então o modelo de treinamento e a matriz de confusão do mesmo. Na etapa de classificação de imagens, foi usado como máscara de entrada o *raster* pertencente ao conjunto de dados do teste e o modelo treinado. Com a classificação, foi aplicada a função *Zonal Histogram*, fornecendo então os valores dos pixels contidos em cada polígono, possibilitando então as respectivas matrizes de confusão, levando em aplicação o teste dos dados, de cada imagem classificada. Todo processo de treinamento e classificação do algoritmo está explicitado na imagem (Figura 3).

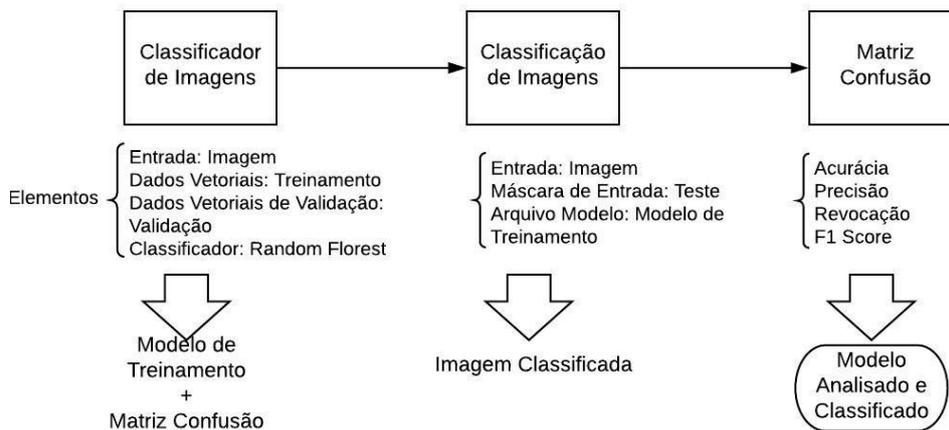


Figura 3. Treinamento e classificação das imagens.

Bem como dito anteriormente, foram obtidas matrizes de confusão de cada imagem classificada, exportadas no formato *xlsx* e iniciou-se a análise. A matriz de confusão tem por finalidade a medição do desempenho da classificação “*Machine Learning*”. Relacionando valores: Verdadeiro positivo (*True positive* - TP), Falso negativo (*False negative* - TN), Falso positivo (*False positive* - FP) e Verdadeiro negativo (*True negative* - FN). Com a relação desses valores, é possível a obtenção da precisão, acurácia, *Recall* (Revocação) e *F1 Score* de cada imagem classificada.

Sendo assim, foram obtidos resultados e a partir deles gerado análises e conclusões sobre este processo realizado, onde se realizou a classificação de imagens de VANT por intermédio do Orfeo Toolbox, levando em consideração o aprendizado do mesmo, *Machine Learning*.

RESULTADOS

Assim sendo, foram alcançadas as produções com as seguintes precisões, tendo como base as estatísticas geradas com auxílio da matriz de confusão, os resultados aproximado-se em média, estão presentes na Tabela 2.

TABELA 2. RESULTADOS

Métricas	Ortofoto	Imagem 1	Imagem 2	Imagem 3	Imagem 4	Imagem 5
Acurácia	0,876	0.904	0.913	0.926	0.781	0.04
Precisão	0.905	0.924	0.932	0.938	0.676	0.360
<i>Recall</i>	0.843	0.896	0.912	0.920	0.780	0.340
<i>F1 Score</i>	0.873	0.910	0.922	0.929	0.726	0.350

Fonte: Autora.

Verifica-se por intermédio da tabela 4, que o comportamento oscilante ocorre em todas as imagens, as mesmas com as respectivas definições presentes na Figura 5, mas resulta na casa do décimo nas composições de *features* *GSMO* e *Haralick* e ao compararmos com a ortofoto, a mesma é inferior as texturas anteriormente expressadas. No qual, pode-se dizer que a junção de bandas fornece mais dados sobre a área de estudo, o que favorece o colhimento de informações precisas.

Ademais, na imagem 4 (*NDVI*), dispôs-se de valores inferiores ao contrapor com as outras imagens, o *NDVI* apresentou em média 78% no *recall*, isto pode ser explicado pela a presença considerável de vegetação, em seu índice variou entre -0.950 e 0.9375, o que indica uma boa resposta espectral e atividade da clorofila tendo como parâmetro que o seu índice varia entre -1 e 1.

Tendo como critério que o valor do *NDWI* varia de -1 para 1 e em concordância com (Mc Feeters, 1996), define-se zero como limiar, ou seja, o tipo de cobertura é água se $NDWI \geq 0$ e quando o $NDWI \leq 0$ considera-se que não é água, (Brubascher, 2013). Se torna justificável os valores métricos da imagem 5 (*NDWI*), pois na imagem classificada existem regiões compostas de água, porém são poucas quando equiparadas as classes de maiores porcentagens sendo a areia e a vegetação.

Em resumo, a imagem com maiores métricas foi a imagem 3 que é resultante da composição de bandas entre a ortofoto, *GSMO* e *Haralick*, precisão essa em torno de 94%, como dito anteriormente, é o produto gerado com maior número de bandas do que o restante, reproduzindo mais detalhes a respeito da região estudada, permitindo então a extração de informações e classificação satisfatória. E para fins coerentes deste estudo, segue abaixo o confronto entre a imagem classificada e o ortofoto, Figura 4.

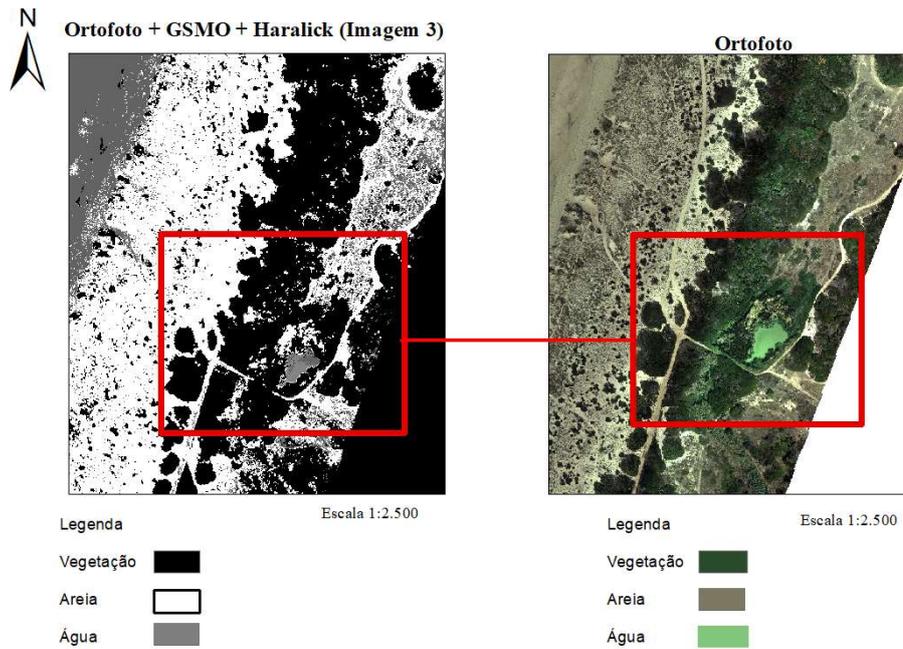


Figura 4. Imagem classificada x ortofoto.

Para melhor expor a ocupação das amostragens na classificação, encontra-se ilustrado (Figura 5) o gráfico em relação às respectivas classes desenvolvidas e suas respectivas bases de operação, Figuras 5.



Figura 5. Percentual.

Com os esquemas acima, nota-se que nas classes de água foi obtida a menor porcentagem, o que é coerente, visto que a parcela dessa categorização é menoridade presente na área classificada. É perceptível também que ao analisarmos que a vegetação e areia também se fazem adequados, visto suas presenças significantes na região mapeada. Desta maneira, no aspecto identificação dos conjuntos presentes no campo discutido, consta-se coerência em seu fichamento.

CONCLUSÕES

Em vista do que foi produzido e expressado, pode-se concluir que, as respostas métricas do UAV tiveram-se precisões significativas e como relatado acima, a resolução espacial e as amostras, principalmente do treino, foram fatores que tiveram influência direta com os resultados. Importante realçar que haverá casos de estudos distintos, onde é mais vantajoso não ter custos com um vôo de VANT e simplesmente realizar o download de uma imagem orbital, ou seja, aquela determinada resolução espacial irá satisfazer o trabalho, situações também de escolher apenas pelo veículo aéreo não tripulável e/ou a junção de tais tecnologias.

E que esta preferência, está diretamente relacionada com o que se espera, isto significa que a precisão de um produto desejado é questão fundamental para que se tenha uma margem de precisão aceitável. Sendo composto por diferentes métodos de treinamento e classificação, como a composição de bandas, metodologia de treinamento e o tipo de imagem escolhida, sejam orbitais e/ou UAV, tendo influência direta com a precisão resultante. Além disto, cabe ao responsável pelo serviço levar em consideração quais as ações pretendidas do projeto, qual precisão satisfatória é atendível e os meios viáveis nos quesitos financeiros, tempo e coleta de dados.

REFERÊNCIAS BIBLIOGRÁFICAS

- GUASSELLI, L. A., B., J. P. Mapeamento da área inundável da planície do rio dos Sinos a partir do índice NDWI. Anais - XVI Simpósio Brasileiro de Sensoriamento Remoto - INPE. p. 4540–4547, 2013.
- LONGHITANO, G. A. Vants para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas. São Paulo: Escola Politécnica da Universidade de São Paulo, 2010.
- MENESES, P. R., A., T. Introdução ao Processamento de Imagens de Sensoriamento Remoto. Brasília: UNB, 2012.
- MCFEETERS, S.K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. p. 1425–1432, 1996.