



## Avaliação do desempenho de algoritmos de classificação orientados a objetos para classificar dados de alta resolução espacial em zonas urbanas

Ricardo ARAÚJO<sup>1</sup>, Ana Cláudia TEODORO<sup>1,2</sup>

<sup>1</sup> Departamento de Geociências, Ambiente e Ordenamento do Território, Faculdade de Ciências, Universidade do Porto, Portugal

<sup>2</sup> Instituto de Ciências da Terra (ICT), FCUP-Universidade do Porto, Portugal

(ricardomirandaaraujo@gmail.com; amteodoro@fc.up.pt)

**Palavras-chave:** Segmentação, Classificação, VANT, SVM

**Resumo:** O uso de Veículos Aéreos Não Tripulados (VANT) para a obtenção de imagens de alta resolução espacial está a tornar-se cada vez mais popular. O objetivo deste trabalho consistiu na aplicação de diferentes algoritmos de classificação orientada a objetos para produzir mapas de ocupação do solo. Usou-se um orto-mosaico (500mx400m) produzido através de 44 fotografias adquiridas com um Swinglet® de uma zona da cidade de Coimbra (pixel de 4 cm). Numa 1ª fase, usando o *software* Spring toda a imagem foi segmentada (*region growing*) e posteriormente classificada (*Bhattacharya*) num total de 7 classes. Após o processamento, que demorou mais de 60 h, foi efetuada uma análise criteriosa dos resultados obtidos. Numa 2ª fase, foram escolhidas 3 zonas que apresentavam bastantes problemas na classificação original e foi repetido o processo considerando 4 e depois 7 classes. Esta escolha fez diminuir o tempo de processamento e permitiu obter uma classificação mais fiável e exata para essas zonas. Com o objetivo de usar algoritmos de data mining que lidam melhor com grande quantidade de dados, foi utilizado o *software* Monteverdi e utilizadas máquinas de suporte vetorial (SVM -*Support Vector Machine*) para a classificação, após uma segmentação recorrendo ao algoritmo "*Mean Shift*". Comparando as classificações obtidas, as obtidas no Monteverdi, usando SVM, apresentam melhores resultados já que classificam totalmente as regiões consideradas. No Spring existem zonas que ficam por classificar. Conclui-se que quanto maior o número de classes, maior possibilidade existe de confusão entre as classes e a exatidão global diminui.



## 1. Introdução

O uso de Veículos Aéreos Não Tripulados (VANT) para aplicações de detecção remota está a tornar-se cada vez mais frequente. Com a rápida melhoria das tecnologias tanto das câmaras e dos próprios veículos, resoluções espaciais sub-decimétricas são agora possíveis, podendo estes dados rivalizar com imagens adquiridas por plataformas espaciais e aéreas, para determinados fins. O baixo custo para produzir imagens de muito alta resolução para pequenas e médias áreas e a sua grande flexibilidade de configuração e utilização são algumas das vantagens do uso de VANT. Com o acesso a este nível de resolução espacial surgem alguns problemas relacionadas com processamento destas imagens (Teodoro e Araújo, 2014).

Nos últimos anos, o aumento do uso de imagens de alta resolução espacial tornou o uso da classificação orientada a objetos (OBIA - *Object Based Image Analysis*) mais comum, devido a normalmente se obterem melhores resultados quando comparados com classificações baseadas no *pixel*, devido à grande variabilidade espacial entre objetos de interesse.

De entre os vários *software* que possuem métodos OBIA, os proprietários são os mais populares e mais usados em trabalhos científicos, muito devido aos seus algoritmos estarem bem testados e serem altamente eficientes. No entanto, existem vários *software open source* como o Spring (Spring, 2014), OTB/Monteverdi (ORFEO Toolbox, 2014) ou o GRASS (GRASS GIS, 2014) que também possuem algoritmos OBIA.

O Spring é um SIG (Sistema de Informação Geográfica) e um *software* de processamento de imagem de detecção remota que integra dados vectoriais e *raster*. O Spring é um *software* da responsabilidade do Instituto Nacional de Pesquisas Espaciais - departamento de processamento de Imagem (INPE/DPI), do Brasil (Camara *et al.*, 1996). De entre as diversas funcionalidades que este *software* apresenta, estão disponíveis vários algoritmos de segmentação e classificação de imagem e ainda diferentes funções estatísticas.

O OTB (Orfeo ToolBox) é uma *toolbox open source* de processamento de imagem para detecção remota desenvolvido pelo Centre National d'Etudes Spatiales (CNES), em França. O Monteverdi é uma interface gráfica que possibilita o uso da maior parte dessas ferramentas de processamento do OTB através do suporte de dados *raster* e vectoriais.

O objetivo principal deste trabalho foi explorar as potencialidades dos métodos OBIA presentes nestes dois *software open source*: Spring (5.2.6) e OTB/Monteverdi (1.23.0) para dados de muito alta resolução espacial obtidos por VANT em zonas urbanas.

A enorme quantidade de dados proveniente dos dados adquiridos pelos VANT introduz novos problemas relacionados com as técnicas "tradicionais" de processamento de imagem. O primeiro passo num método OBIA é a segmentação. A segmentação tem como principal objectivo a criação de objectos que melhor representem a imagem. Teodoro e Araújo (2014) realizaram uma série de segmentações (*region-based*) usando uma combinação de parâmetros de similaridade e de área para posteriormente ser efectuada uma classificação supervisionada orientada a objectos (*Bhattacharya*) considerando 7 classes baseadas na nomenclatura da Corine Land Cover (CLC). Durante este processamento foram encontrados diversos parâmetros que produziam bons resultados. A combinação que obteve melhores resultados (Exatidão Global (EG) > 90% e Kappa > 0.9) foi a segmentação que utilizava valores de área de 100 e similaridade de 5. Combinações de baixos valores para a similaridade e área e de altos valores para a similaridade e área foram os que produziram piores resultados. Essas combinações produziam objectos ou muito grandes ou demasiados pequenos em relação aos objectos presentes na imagem. Devido à alta resolução espacial dos dados usados (4 cm), o uso de uma classificação não supervisionada (usando uma combinação de 20 para similaridade e 25 para a área), produziu 27 classes distintas. Devido a este número de classes ser bastante elevado, foi realizada uma nova classificação supervisionada usando 22 classes. Apesar dos resultados da nova classificação serem inferiores ao obtidos para as 7 classes, esta produziu um resultado mais detalhado e mais próximo da realidade. Foi possível concluir que os algoritmos usados em Teodoro e Araújo (2014) não são os mais apropriados para este tipo de resolução espacial e tamanho de imagem. Além disso, o processamento dos dados foi muito demorado (> 60 horas), sendo recorrente o aparecimento de *bugs* e *software crashes*. O uso de algoritmos mais robustos poderiam melhorar os resultados. Neste trabalho foram usadas duas abordagens usando diferentes *softwares open source*. Para resolver o problema do tamanho da imagem, novas zonas de teste foram definidas (I, II, e III – Figura 1). Estas regiões foram escolhidas por mostrarem diversos problemas em trabalho anteriores (Teodoro e Araújo, 2014).

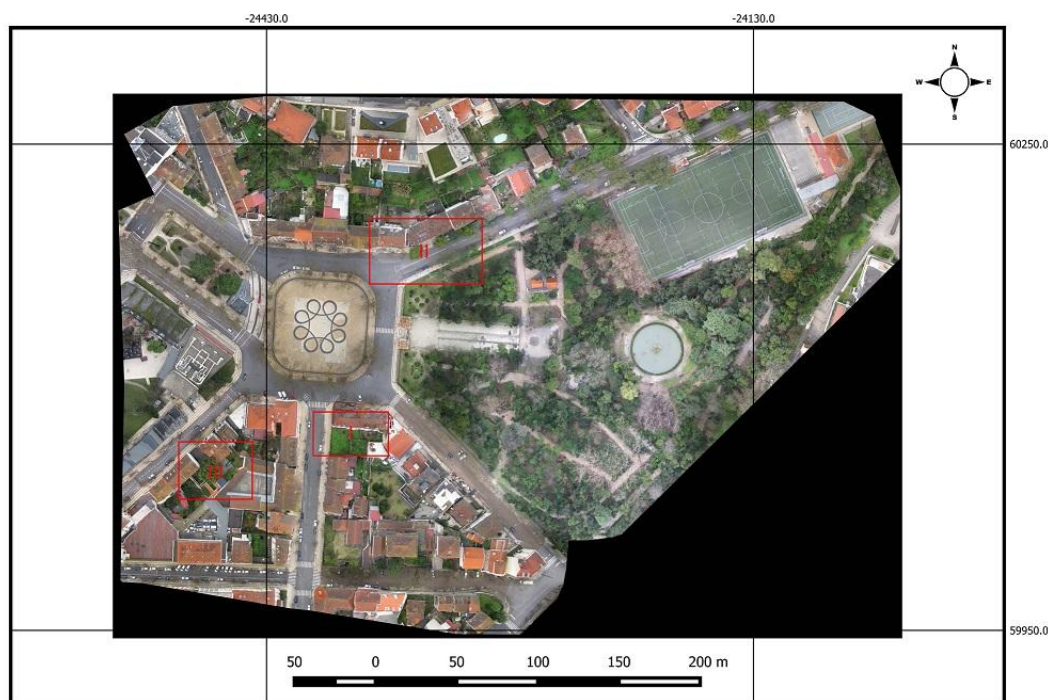
## 2. Metodologia

A metodologia aplicada para a realização deste trabalho envolveu três fases.

1. Recolha das imagens, orto-retificação, orto-mosaico e escolha das zonas de teste.
2. Processamento da informação nos dois *software*:
  - 2.1. Spring: Segmentação usando o algoritmo *Region Growing* (RG) e classificação com o algoritmo *Bhattacharya*.
  - 2.2. Monteverdi/OTB: Segmentação a partir do algoritmo MSS (Mean Shift Segmentation) e classificação utilizando SVM.
3. Análise e interpretação dos dados obtidos.

O VANT usado para a recolha das imagens foi um Swinglet da marca Sensefly®. O swinglet CAM tem um tempo de vôo máximo de 30 minutos, permitindo cobrir uma área de aproximadamente 6 km<sup>2</sup> num único voo. Possui uma camera de 12 MP o que lhe permite recolher imagens aéreas com uma resolução espacial de até 4 cm/pixel. Orto-mosaicos e modelos de elevação 3D podem ser criados a partir destas imagens. As 41 imagens recolhidas no dia 20 de Janeiro de 2012 de zona urbana da cidade de Coimbra tinham uma sobreposição lateral de 60% e uma sobreposição longitudinal de 80% para permitir um melhor mosaico para gerar uma imagem final da área total de estudo.

A orto-rectificação (RMS 0.0076 m planimétrico e 0.742 m altimétrico) e o orto-mosaico foram produzidos usando o *software* Agisoft PhotoScan Professional Edition (Agisoft LLC, S.Petersburg, Russia). O resultado foi um orto-mosaico com 0.04 m de resolução e com uma área coberta de aproximadamente 500x400 m (Figura1).



**Figura 1** – Orto-mosaico da zona de estudo, com a identificação das três regiões de interesse (RI) assinaladas a vermelho: I, II e III

### 2.1 Segmentação

Teoricamente qualquer algoritmo de segmentação pode ser usado em imagens de deteção remota, no entanto o maior problema é definir os parâmetros da segmentação que melhor representem os diferentes tamanhos, formas e cores que compõem uma imagem de elevada resolução espacial (Blaschke e Hay, 2001).



O algoritmo *Region Growing* (RG), que está disponível no software Spring, é um método designado de “crescimento por regiões” e que parte do pressuposto que os píxeis vizinhos dentro da mesma região deveriam ter valores semelhantes (Tremeau e Boel, 1997; Hojjatoleslami e Kittler, 1998). A aplicação deste algoritmo requer que seja introduzido um valor de similaridade, valor esse que se for demasiado baixo vai gerar regiões demasiado segmentadas e o contrario, caso esse valor seja elevado, as regiões a serem geradas serão muito grandes e a imagem será pouco segmentada. Este valor juntamente com o parâmetro da área, são dependentes da aplicação e do tipo de imagem (Bins *et al.*, 1996).

O outro algoritmo usado e disponível no OTB/Monteverdi, o *Mean Shift Segmentation* (MSS) tem vindo a ser bastante usado na comunidade de deteção remota (Jiang *et al.*, 2008; Huang e Zhang, 2008; Ming, 2012). Este método foi introduzido por Fukunaga e Hostetler em 1975 (Fukunaga e Hostetler, 1975). No entanto, o MSS não é um algoritmo de segmentação puro. Mais considerações sobre este algoritmo podem ser consultadas em Michel *et al.*, (2015).

## 2.2 Classificação

Os métodos OBIA tem como princípio a classificação dos objetos presentes na imagem em objetos de interesse geográfico. O segundo passo é assim classificar os diferentes objectos originados pela segmentação e agrupá-los em classes de ocupação do solo.

O algoritmo de classificação *Bhattacharya* é um método de classificação supervisionado para classificação de imagens segmentadas, isto é, o objeto a ser classificado não é necessariamente um pixel mas pode ser uma região da imagem. Este algoritmo está disponível em vários *software*, como por exemplo, no Spring. Mais detalhes acerca deste método pode ser consultado em Choi e Lee (2003).

O uso de SVM tem vindo a demonstrar uma elevada eficácia em diversas aplicações de deteção remota (Bruzzone e Carlin, 2006; Camps-Valls e Bruzzone, 2009). Têm sido efetuados vários estudos, focados no problema da alta resolução espacial usando SVM para classificação de uso de solos (Inglada, 2007; Tuia *et al.*, 2009). Os SVM são classificadores supervisionados utilizando o princípio teórico de Vapnik's. Mais informações acerca deste método pode ser encontrado em Volpi *et al.*, (2013).

A avaliação de exatidão é um passo importante no processo de classificação. A matriz de confusão permite fazer uma análise descritiva e analítica dos resultados. Mais considerações sobre a avaliação da exatidão da classificação pode ser consultada em Congalton e Green (2008). Neste trabalho a Exatidão Global (EG) foi avaliada para cada classificação realizada.

## 3. Resultados e discussão

Os resultados obtidos a partir dos algoritmos descritos nas secções anteriores foram realizados num computador com as seguintes características: CPU Intel 2500k a 4.8GHz e 12 GB de memória RAM.

O tempo necessário para a segmentação e classificação de uma imagem com uma resolução espacial tão elevada pode ser extremamente demorada, como foi comprovado em Teodoro e Araújo (2014). A utilização de zonas mais pequenas resolve este problema tornando o processamento da imagem muito mais rápido. Foram escolhidas quatro zonas para testar os diferentes algoritmos nos dois *software*. Estas 4 zonas presentes nas 3 áreas de interesse mais abrangentes e assinaladas na Figura 1 representam algumas zonas problemáticas encontradas em classificações anteriores (Teodoro e Araújo, 2014). A zona 1 (Figura 2) pertence à RI I, a zona 2 pertence à RI II e as zonas 3 e 4 pertencem à RI III.

Cada uma das zonas escolhidas foca-se em locais específicos de áreas mais abrangentes e de onde foram selecionadas as áreas de treino necessárias para a definição das classes. A primeira zona (Figura 2a) situa-se numa área onde a existência de um automóvel na via pública apresenta alguns problemas para o processamento da imagem, logo um dos objetivos para esta zona é a correta classificação desse automóvel. A segunda zona (Figura 2b) apresenta diversas adversidades à produção de uma boa classificação, como por exemplo, a presença de ecopontos na berma da via. A terceira e quarta zona (Figuras 2c e 2d, respetivamente) fazem parte da mesma RI (RI III) onde a presença de clarabóias, painéis solares e automóveis numa área bastante pequena torna a classificação bastante complexa.



### 3.1 Spring

Usando as áreas de interesse referidas anteriormente, foi aplicado o algoritmo de segmentação RG. Os parâmetros usados para a segmentação foram de 100 para a área e de 5 para a similaridade, de acordo com o discutido em Teodoro e Araujo (2014).

As 4 classes usadas para esta classificação foram: Habitação (cor-de-laranja), Asfalto (cinzento), Vegetação (verde) e Pavimento (amarela). Apesar dos resultados da EG (Quadro 1) obtidos por deste método produzirem resultados muito bons, é possível observar na Figura 2 (e, f, g, e h) que existem várias zonas das imagens que apresentam alguns erros. O maior problema é a falta de classificação de algumas zonas da imagem (cor branca). Essa falha é bastante visível na terceira zona (Figura 2g) onde o painel solar fica todo por classificar. Esta falta de classificação pode ser colmatada com o aumento do número de classes como foi comprovado em Teodoro e Araújo (2014). Na Figura 2f é possível observar que a presença de ecopontos na imagem, devido à sua cor diferente, induz o algoritmo a produzir resultados confusos para essa zona e a não classificar parte da imagem. A presença de clarabóias e de dois automóveis na zona 4 (Figura 2h), acarreta grandes problemas à classificação da imagem.

### 3.2 Monteverdi

Antes de se poder aplicar uma classificação supervisionada usando SVM, é necessário, primeiro, realizar uma segmentação. O algoritmo de segmentação presente no *software* Monteverdi é o MSS. A partir do módulo de *Object Clustering* é possível produzir segmentações usando os 3 parâmetros necessários: *spatial radius*, *spectral radius* e *minimum region size*. Várias combinações destes parâmetros foram feitas e foi escolhida a opção que melhor representava os objetos presentes na imagem. Essa combinação usou o valor 15 para *spatial radius*, 15 para *spectral radius* e 500 para *minimum region size*. Foram escolhidas as mesmas 4 classes usadas no Spring.

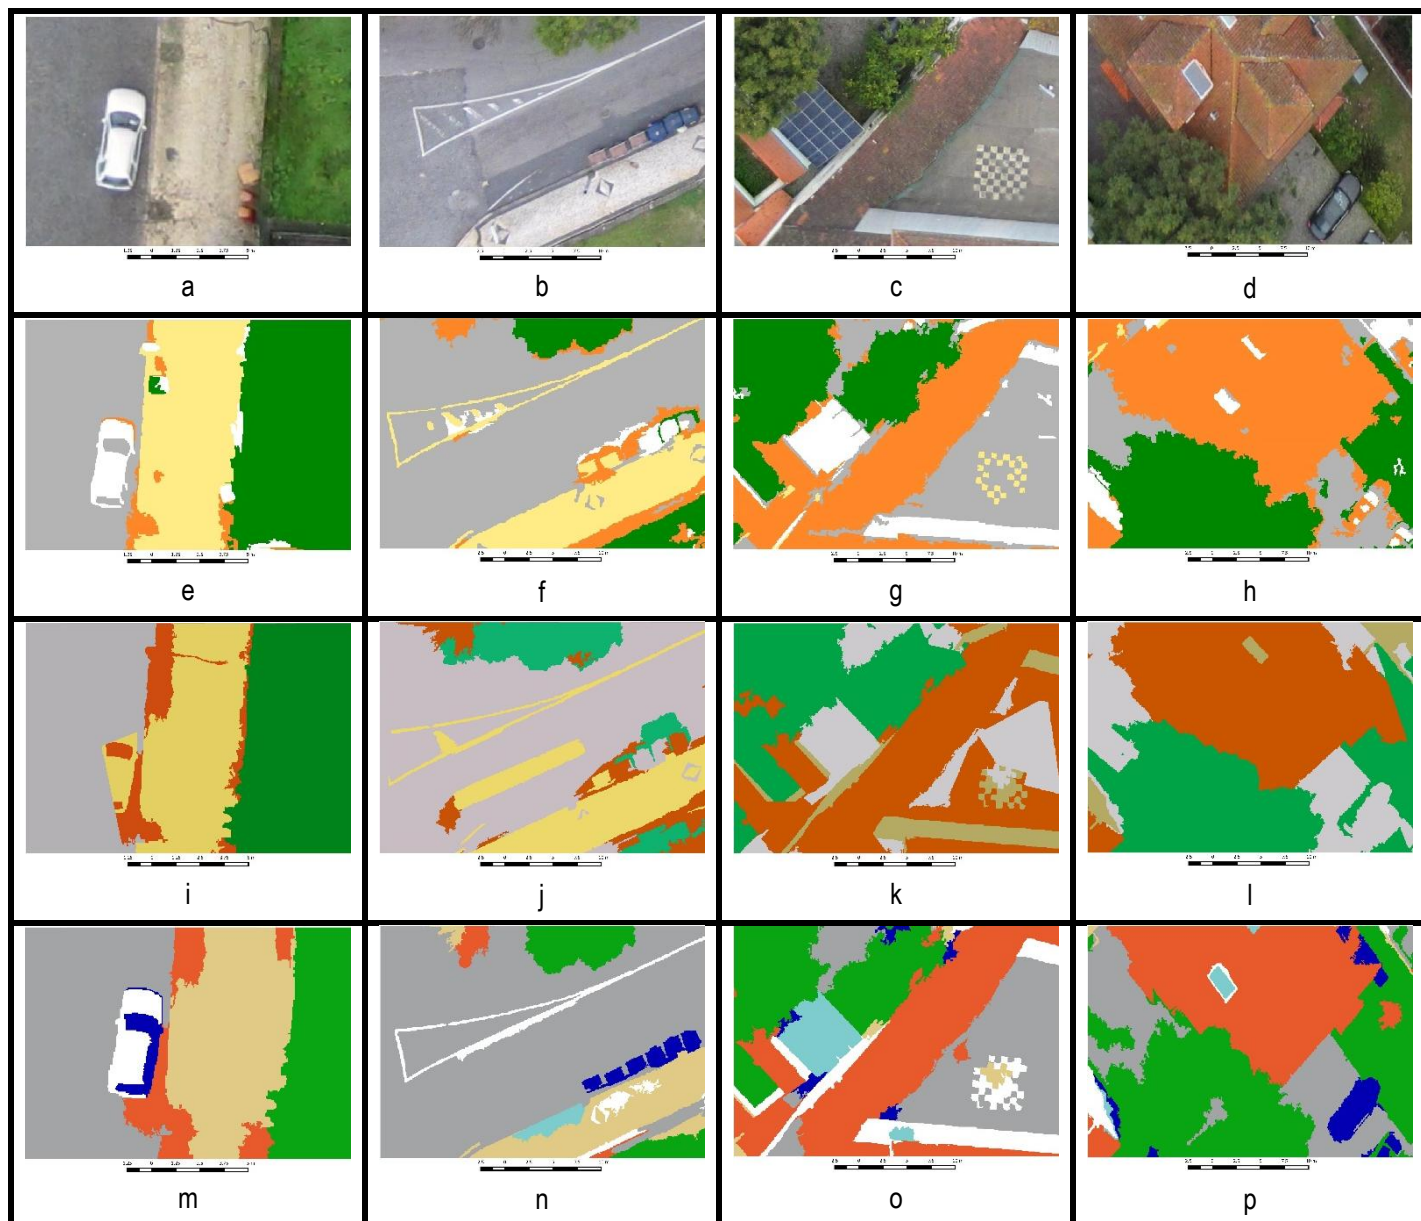
Apesar de produzir resultados de EG muito próximos dos obtidos no Spring, como se pode observar no Quadro 1, após uma análise visual é possível ver que na realidade produzem classificações muito distintas. O algoritmo SVM não deixa pixels sem classificação. Ao contrário do Spring, o Monteverdi classifica a totalidade dos pixels mesmo que isso signifique que os objetos sejam mal classificados. A classificação total de todos os pixels leva a que em zonas em que exista maior confusão por sobreposição ou proximidade de objetos distintos produza resultados bastante confusos.

Na Figura 2k é possível notar que perto do local do padrão xadrez na imagem exista uma grande confusão com a classificação tendo até classificado parte desse pátio em cimento como habitação. Na zona 1 (Figura 2i) o carro é classificado em 3 classes diferentes.

#### 3.2.1 Introdução de mais classes

Para tentar resolver o problema de existirem objetos mal classificados, devido à grande quantidade de informação presente na imagem, foram criadas mais classes (6 ou 7, dependendo da área a analisar): Habitação (cor-de-laranja), Asfalto (cinzenta), Vegetação (verde), Pavimento (amarela), Tinta (branca), Vidro (azul claro) e Outro (azul escuro). A classe "Outro" foi introduzida para representar objetos que apresentam cor ou forma diferente do tudo o resto que possa ser relevante e que se pretende classificar. A classe "Tinta" representa a tinta que é visível em algumas zonas da parte lateral dos edifícios e de estruturas pintadas.

Sabendo que a cor tem um peso elevado na decisão de um algoritmo, o carro presente na zona 1 (Figura 2m) é mal classificado, que devido à sua cor branca é classificado erradamente como "Tinta". Na zona 2 (Figura 2n), com o uso de mais classes e com a utilização da classe "Outro" para representar os ecopontos presentes na imagem é possível verificar uma melhoria significativa, apesar de se obter uma EG inferior às classificações com 4 classes. Na zona 3 (Figura 2o) é possível observar que grande parte dos problemas encontrados nas classificações em que apenas eram usadas 4 classes (painel solar e xadrez no pavimento) são parcialmente ou totalmente resolvidos. O painel solar devido às suas propriedades espectrais ficou agregado à classe "Vidro". O mesmo acontece com o padrão, apesar de no interior parte do padrão ser classificado como "Pavimento" o resto do padrão é corretamente classificado como "Tinta" e os seus limites ficam mais definidos.



**Figura 2** – Imagens das 4 zonas de teste originais na primeira linha (a-d), com as classificações obtidas no Spring com 4 classes na segunda linha (e-h) e as classificações obtidas no MonteVerdi na terceira e quarta linha com 4 (i-l) e 7 classes (m-p), respectivamente.

### 3.2.2 Comparação de resultados

Como foi previamente discutido, os resultados das classificações com mais classes produziram resultados piores comparativamente com os resultados obtidos com apenas 4 classes, quando analisamos a EG. Apesar de os resultados obtidos no Spring e no MonteVerdi, para as 4 classes, produzirem classificações bastante distintas visualmente, as EG obtidas nestes dois softwares estão muito próximas, como é possível observar no Quadro 1. As 4 zonas analisadas neste trabalho foram extraídas das 3 RIs definidas na Figura 1, pelo que as conclusões tiradas para estas zonas são idênticas.



**Quadro 1** – Exatidão global (EG) para as 3 RI

RI	Spring (4 classes)	OTB/Monteverdi (4 classes)	OTB/Monteverdi (7 classes)
I	96,70%	96,70%	91,81%
II	94,90%	94,40%	87,04%
III	91,10%	92,80%	85,45%

Apesar de os resultados da EG serem na sua globalidade inferiores com o uso de mais classes, visualmente a classificação obtida é mais fiel à representação da realidade. Os tempos de processamento nos dois *software* foram muito próximos, apesar do Monteverdi ser ligeiramente mais rápido em todas as zonas consideradas.

#### 4. Conclusões

O principal objetivo deste trabalho foi explorar e testar métodos OBIA para processar dados adquiridos por um VANT. Devido a problemas encontrados em trabalhos anteriores, o uso de áreas de interesse para diminuir a quantidade de dados a processar provou ser um método eficiente para diminuir o tempo de processamento. Infelizmente não foi possível obter resultados com outros *software*. Visto ainda ser uma abordagem muito recente, são ainda poucos os *software* livres que possuem estes algoritmos e que consigam lidar com a quantidade de dados que um levantamento VANT pode gerar. Apesar dos valores da EG não comprovarem o que foi verificado visualmente, pode-se afirmar que o classificador SVM provou ser o melhor algoritmo quando foram consideradas 7 classes. Pode-se concluir que a grande quantidade de dados produzida por VANT não é adequada para a produção de mapas de ocupação de solo diretamente devido à grande quantidade de informação. O aumento necessário do número de classes, apesar de obter melhores resultados visuais, pode não estar conforme as normas para a produção desses mapas, como por exemplo a norma CLC. No entanto, este tipo de nível de informação pode ser usado caso seja necessária uma grande discriminação do uso do solo.

#### Agradecimentos

Os autores gostariam de agradecer à Sinfic SA (Eng. João Marnoto) pela cedência dos dados UAV e ao Prof. José Alberto Gonçalves pelo pré-processamento dos dados.



## Referências Bibliográficas

- Bins, L.S.; Fonseca, L.M.G.; Erthal, G.J. (1996). Satellite Imagery Segmentation: a region growing approach. Proc. of III Simpósio Brasileiro de Sensoriamento Remoto, Salvador, Brasil, INPE, Págs. 677-680.
- Blaschke, T.; Hay, G. (2001). Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multi-scale landscape structure. *International Archives of Photogrammetry Remote Sensing*, Vol. 34. No. 2, Págs. 22–29.
- Bruzzone, L.; Carlin, L. (2006). A multilevel context-based system for classification of very high spatial resolution images. *IEEE Trans. Geosci. Remote Sens.*, Vol. 44, Págs. 2587–2892.
- Camara, G.; Souza, R.C.M.; Freitas, U.M.; Garrido, J. (1996). Spring: Integrating remote sensing and GIS by object-oriented data modelling. *Computers & Graphics*, Vol. 20, No.3, Págs. 395-403.
- Camps-Valls, G.; Bruzzone, L. (2009). *Kernel Methods for Remote Sensing Data Analysis*. J. Wiley & Sons.
- Choi, E.; Lee, C. (2003). Feature extraction based on the Bhattacharyya distance. *Pattern Recognition*, Vol. 36, No. 8, Págs. 1703–1709.
- Congalton, R.G.; Green, K. (2008). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices (Second Edition)*.
- Fukunaga, K.; Hostetler, L. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Trans. Inf. Theory*, Vol. 21, No.1, Págs. 32–40.
- GRASS GIS, <http://grass.osgeo.org/>, consultada em 13 setembro 2014
- Grizonnet, M.; Inglada, J. (2010). Monteverdi - Remote Sensing Software from Educational to Operational Context, *Remote Sensing for Science, Education, and Natural and Cultural Heritage*. Rainer Reuter (Editor), EARSeL, Págs.749-756.
- Hojjatolleslami S.A.; Kittler, J. (1998). Region growing: a new approach. *IEEE Transactions on Image Processing*, Vol.7. No. 7, Págs. 1079-1084.
- Huang, X.; Zhang, L. (2008). An adaptive mean-shift analysis approach for object extraction and classification from urban hyperspectral imagery. *IEEE Trans. Geosci. Remote Sens.*, Vol. 46, No. 12, Págs.4173–4185.
- Inglada, J. (2007). Automatic recognition of man-made objects in high resolution optical remote sensing images by SVM classification of geometric image features. *ISPRS J. Photogramm. Remote Sens.*, Vol. 62, Págs. 236–248.
- Jiang, N.; Zhang, J.; Li, H.; Lin, X. (2008). Semi-automatic building extraction from high resolution imagery based on segmentation. in Proc. Int. Workshop EORSA, Págs.1–5.
- Michel, J.D.; Youssefi, D.; Grizonnet, M. (2015). Stable Mean-Shift Algorithm and Its Application to the Segmentation of Arbitrarily Large Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 35, No.2, Págs. 952-964.
- Ming, D. (2012). Semivariogram-based spatial bandwidth selection for remote sensing image segmentation with mean-shift algorithm. *IEEE Geosci. Remote Sens. Lett.*, Vol. 9, No.5, Págs.813–817.
- Spring - DPI/INPE, <http://www.dpi.inpe.br/spring/english/>, consultada em 19 março 2014
- ORFEO Toolbox, <http://www.orfeo-toolbox.org/>, consultada em 13 setembro 2014
- Teodoro A.C.; Araújo R. (2014). Exploration of the OBIA methods available in SPRING noncommercial software to UAV data processing. Proc. SPIE 9245, *Earth Resources and Environmental Remote Sensing/GIS Applications V*.
- Tremeau A.; Bolel, N.(1997). A region growing and merging algorithm to color segmentation. *Pattern Recognition*, Vol. 30, No. 7, Págs. 1191-1203
- Tuia, D.; Pacifici, F.; Kanevski, M.; Emery, W.J. (2009). Classification of very high spatial resolution imagery using mathematical morphology and support vector machines. *IEEE Trans. Geosci. Remote Sens.*, Vol. 47, Págs. 3866–3879
- Volpi, M.; Tuia, D.; Bovolo, F.; Kanevski, M.; Bruzzone, L. (2013). Supervised change detection in VHR images using contextual information and support vector machines. *International Journal of Applied Earth Observation and Geoinformation*, Vol. 20, Págs.77–85.