



**Imagens de Alta Resolução Espacial de Veículos Aéreos
Não Tripulados (VANT) no Planejamento do Uso e Ocupação do Solo**
High Spatial Resolution Images of Unmanned Aerial
Vehicle (UAV) in Land Use and Occupancy Planning

Anny Keli Aparecida Alves Cândido¹;
Normandes Matos da Silva² & Antonio Conceição Paranhos Filho¹

¹ Universidade Federal de Mato Grosso do Sul, Laboratório de Geoprocessamento para Aplicação Ambiental,
Unidade 7A, 78720-100. Campo Grande, Mato Grosso do Sul, Brasil

² Universidade Federal de Mato Grosso. Bairro Sagrada Família,
Rodovia MT 270, km 6, saída para Guiratinga, 78735-910. Rondonópolis, Mato Grosso, Brasil
E-mails: Anny.keli@hotmail.com; normandes@pq.cnpq.br; antonio.paranhos@pq.cnpq.br

Recebido em: 11/09/2014 Aprovado em: 23/03/2015

DOI: http://dx.doi.org/10.11137/2015_1_147_156

Resumo

A criação, aperfeiçoamento e uso de técnicas de sensoriamento remoto com foco em imagens suborbitais vêm aumentando, por apresentarem uma série de vantagens na análise geográfica e ecológica, produzindo dados com alta resolução espacial. O objetivo desse trabalho foi testar técnicas de classificação supervisionada e não supervisionada em imagens aéreas digitais de alta resolução espacial obtidas por veículo aéreo não tripulado (VANT), empregando dois softwares, SPRING e ArcGis. As imagens aéreas possuem resolução espacial de aproximadamente 10 cm, com área útil de recobrimento em torno de 45%. Foram obtidas em junho de 2011 e recobrem um trecho da cabeceira do rio São Lourenço, Campo Verde-MT. As fotografias aéreas foram georreferenciadas e posteriormente foram realizados os testes de classificação, dentre os quais apresentaram melhores resultados as classificações por região. Nessa etapa foram realizados aproximadamente 100 testes de segmentação com parâmetros de similaridade e área diferenciados, até encontrar uma rotina que melhor se adequasse a área de estudo. A classificação que melhor delimitou as diferentes feições presentes na imagem foi a supervisionada por região, cuja segmentação possuía 20 pixels de similaridade e 200 de área. Para comprovar estatisticamente a eficiência da classificação foi realizado teste de cluster e a validação foi realizada por meio do índice kappa e exatidão global. Os resultados apresentados assim como o uso de VANT, são ótimas ferramentas e passíveis de utilização em diversas áreas, incluindo rotina de perícia ambiental e monitoramento de recuperação de áreas degradadas, no âmbito do Código Florestal Brasileiro.

Palavras-chave: Área de Preservação Permanente (APP), Plano de Recuperação de Áreas Degradadas (PRAD); DRONE

Abstract

The creation, improving and use of remote sensing techniques focused on suborbital images are increasing, as they present several advantages in geographical and ecological analysis, producing high spatial resolution data. The aim of this work was to test the supervised and unsupervised classification techniques in aerial digital images with high spatial resolution obtained by Unmanned Aerial Vehicle (UAV), using the softwares SPRING and ArcGis. The aerial images have spatial resolution in approximately 10 cm, covering around 45% of the floor area. They were obtained in June, 2011, and overlies a stretch of the headwaters of the São Lourenço river in Campo Verde, Mato Grosso. The aerial photographs were georeferenced and then the classification tests were performed, which presented better results the ones by region. At this stage, about 100 segmentation tests were performed with distinguished similarity parameters and areas, until finding a routine that would fit better to the study area. The classification that better delimited the different features present in the images was the supervised by region, whose segmentation had 20 pixels of similarity and 200 of area. To prove statistically the efficiency of classification, a cluster test was performed and the validation was done through Kappa index and overall accuracy. The presented results along with the use of UAVs are great tools and liable to use in several areas, including environmental expertising routines and recovery of degraded areas monitoring, under the Brazilian Forest Code.

Keywords: Permanent Preservation Areas; Plan for Recovery of degraded Areas; DRONE

1 Introdução

A expansão acelerada das atividades agropecuárias sobre os remanescentes vegetais nativos do Cerrado causam uma série de perturbações nos processos e na estrutura dos ecossistemas, culminando com redução da biodiversidade. Como é o caso das matas ripárias, que apesar de possuir importante função na proteção dos recursos hídricos, estão perdendo suas áreas devido ao desmatamento irregular (Martins, 2001).

As geotecnologias surgem como uma importante ferramenta para a fiscalização e análise ambiental, facilitando o gerenciamento da superfície terrestre, bem como dos recursos nela contidos, de forma a contribuir decisivamente para o monitoramento, simulação de cenários e apontar soluções em relação a diferentes formas de uso e ocupação das terras (Leite *et al.*, 2010).

Zhou & Troy (2008) relatam que, para mapeamentos mais complexos, com áreas mais heterogêneas, como é o caso de áreas urbanas, imagens de média resolução espacial são insuficientes para mapeamentos de cobertura do solo, pelo fato de existir feições com dimensões físicas menores que a área de um pixel, a exemplo de imagem Landsat TM 5 que, convencionalmente, possui pixel com área de 900 m².

Com o avanço tecnológico ocorrido nas últimas décadas, vem crescendo o uso de veículos aéreos não tripulados (VANT), por apresentarem vantagens técnicas e econômicas. Sua ampla utilização deve-se a facilidade de adaptação às necessidades de cada projeto, pois as características das imagens estão diretamente relacionadas a parâmetros como resoluções, escalas e tipos de sensores, que são escolhidos de acordo com a necessidade de cada trabalho (Morgan *et al.*, 2010).

Imagens aéreas com alta resolução espacial e temporal contribuem para obtenção de informações em campo, caracterização do problema e até a geração de cartas temáticas em escala de elevado detalhe. Imagens aéreas estão sendo usadas com enfoques diferenciados, como no monitoramento de copas de árvores em ruas de áreas urbanas (Lima Neto *et al.*, 2012), classificação de cobertura do solo (Perea *et al.*, 2010), monitoramento agrícola (Xiang & Tian, 2011), estimativa de índice de área foliar (Córcoles *et al.*, 2013) e produção de mapas georreferenciados em alta resolução espacial (Bryson *et al.*, 2010).

A maioria dos trabalhos realizados a partir de imagens aéreas ocorre por meio de fotointerpretação e, dependendo da complexidade das feições presentes na área, o trabalho pode demandar muito tempo, devido ao volume de dados e características das classificações, carecendo ainda da experiência e conhecimento do fotointérprete (Paranhos Filho *et al.*, 2008).

Visando dinamizar o tempo de processamento de dados e ampliar a eficiência dos produtos gerados por interpretação de imagens aéreas suborbitais, o presente estudo testou diversas técnicas de classificação digital, para verificar a eficiência das mesmas, na caracterização de formas de uso e ocupação do solo, numa escala espacial refinada, com vistas a oferecer uma rotina de procedimentos para uso de VANT no monitoramento e perícia ambiental.

2 Material e Métodos

2.1 Área de Estudo

A bacia hidrográfica do rio São Lourenço possui suas nascentes na região sudeste de Mato Grosso (Figura 1), abrangendo 26.623 km² (SEMA, 2010). Nessa bacia, encontram-se municípios como Barão de Melgaço, Santo Antônio do Leverger, Campo Verde, Jaciara, Juscimeira, Rondonópolis e alguns municípios da sua Microrregião. (Loverde-Oliveira & Nascimento, 2004). O rio São Lourenço nasce no planalto e contribui para formação da bacia hidrográfica do Pantanal Mato-grossense.

A vegetação da nascente do rio São Lourenço é caracterizada, de forma geral, por cerrado *stricto-sensu*, apresentando formações de porte florestal, como por exemplo, Floresta Estacional Semidecidual (SEMA, 2010). Segundo Checoli (2012) a vegetação nativa foi desmatada a partir da década de 1980 para dar lugar à agricultura intensiva.

De acordo com Felfili (2002) o cerrado *stricto-sensu* apresenta-se sobre terrenos planos de solos profundos, que são propícios à agricultura mecanizável, por ter boas condições físicas, sendo também, propícios à pecuária, dentre outras atividades antrópicas.

As Florestas Estacionais Semidecíduais representam uma fisionomia vegetal condicionada à dupla estacionalidade climática, apresentando perda

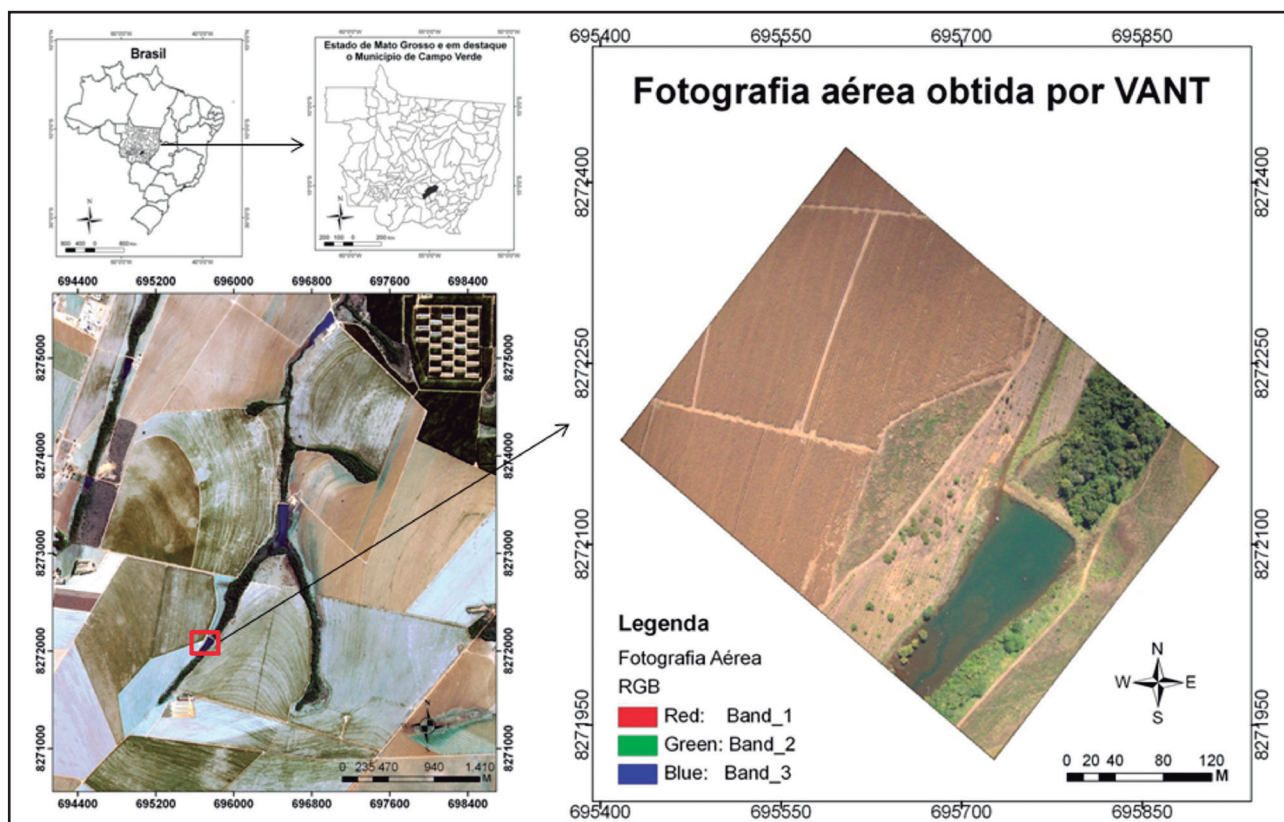


Imagem Spot à esquerda e Fotografia Aérea: Projeção: UTM, Datum: WGS_1984, zona: 21S
Figura 1 Localização das nascentes do rio São Lourenço, com destaque à área de estudo.

de folhas do conjunto florestal (não das espécies), na ordem de 20 e 50%. Os sub-tipos deste tipo florestal são: aluvial, das terras baixas, sub-montana e montana (Ribeiro & Walter, 1998).

2.2 Aquisição de Imagens Aéreas

As imagens aéreas foram obtidas em junho de 2011 por meio de um Veículo Aéreo Não Tripulado (VANT), modelo Tiriba, que sobrevoou e obteve o registro do setor de nascente do rio São Lourenço, em Campo Verde, sudeste de Mato Grosso.

A câmera utilizada para aquisição das imagens foi uma Canon Power Shot S95, com resolução de 3648 x 2736, sensor 1/1.7, 10 Megapixel, CCD (*Charged Couple Device*), lente de 28 – 105 milímetros (35 mm equivalente), $f = 6.0 - 22.5$ mm, zoom ótico 3.8x e $f2.0-4.9$, (AGX, 2011). A altitude do voo foi de 290m, com velocidade de 100 km/h. As imagens apresentaram recobrimento Vertical de 40% e horizontal de 60%, com resolução espacial de aproximadamente 10 cm e área útil em torno de 45%.

A missão gerou 178 imagens aéreas que foram disponibilizadas no formato JPG e RAW, incluindo arquivos acessórios de sincronização de cada cena, conferindo as mesmas um ponto de amarração de coordenada geográfica (latitude/longitude), com datum WGS 1984. Para efeito de testes de classificação, foi selecionada uma imagem aérea. A imagem selecionada foi transformada do formato RAW, para o TIFF, a partir do software Able RAWer (Softonic, 2011). O arquivo TIFF foi georreferenciado no software ArcGis/ArcMap (ESRI, 2010), por meio de imagens de referência (SPOT) disponibilizadas pela SEMA (SEMA, 2010), bem como, por imagens hospedadas na plataforma Google Earth (Google, 2011). Aproximadamente 30 pontos de campo obtidos por meio de receptor GPS de 12 canais, também foram utilizados nessa etapa.

2.3 Classificação das Imagens Aéreas

Os testes de classificação foram realizados em uma cena, que abrangeu: área de aproximadamente 123.000 m², com fisionomia diversificada em termos

de cobertura do solo, englobando um corpo hídrico (uma das nascentes do rio São Lourenço); área ocupada por lavoura altamente mecanizada; ambiente em recuperação com área de 7000m² denominado de unidade demonstrativa de restauração ecológica (UDRE), além de vegetação rasteira e vegetação de porte herbáceo-arbustivo.

Foram testados procedimentos de classificação de imagem supervisionada e não supervisionada programas SPRING (INPE, 2012) e ArcGis/ArcMap (ESRI, 2010). O procedimento para classificação supervisionada e não supervisionada adotados estão descritos na Figura 2.

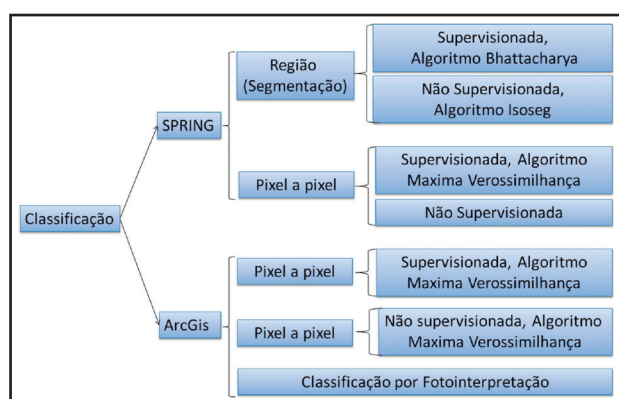


Figura 2 Fluxograma da metodologia adotada.

A rotina de classificação selecionou *a priori* diferentes algoritmos de classificação, com exceção do procedimento de classificação não supervisionada por pixel a pixel no software SPRING, onde o mesmo é realizado no *menu* contraste adotando-se operação linear e fatiamento normal, nessa classificação não é possível escolher algoritmo.

Para realização da classificação por região no software SPRING, as imagens aéreas passaram por um processo chamado de segmentação, que se baseia nas características de descontinuidade e similaridade dos tons de cinza de uma imagem, principalmente quando há mudança abrupta desses valores (Gonzales & Wintz, 1987). Além do contraste, valores espectrais ou textura e atributos espaciais e de contexto que também são considerados (Moigne & Tilton, 1995).

Buscando encontrar uma segmentação que agrupasse com êxito as diferentes classes de cobertura do solo, foram realizados aproximadamente

100 testes de segmentação usando diferentes combinações de similaridade e área. A similaridade é o limiar mínimo e abaixo desse, duas regiões são consideradas análogas e agrupadas em um único polígono. A área corresponde ao valor mínimo de área dado em número de pixel para que uma região seja individualizada (Rudorff *et al.*, 2005).

Como referência para fins de comparação, foi realizada uma classificação por fotointerpretação onde as diferentes classes de uso, foram delimitadas visualmente, a partir de vetorização, procedimento este considerado padrão em trabalhos com imagens aéreas. Nessa etapa foram gerados polígonos delimitando classes de cobertura do solo presente na imagem, sendo que as mesmas receberam código e nome. Esse procedimento ocorreu no software ArcGis/ArcMap (ESRI, 2010).

2.4 Procedimento para Validação das Classificações

Para a obtenção da confiabilidade dos mapas, geraram-se pontos que foram visitados em campo. Esses pontos foram gerados de forma aleatória a partir da extensão (*plugin*) “Hawth’s Analysis Tools” (Spatial Ecology, 2012) do programa ArcGis.

As imagens aéreas, com os pontos sobrepostos foram impressas, para conferência em campo. Em campo (Junho de 2012) 28 pontos previamente sorteados no SIG foram localizados, fotografados e as coordenadas foram coletadas por meio de um receptor GPS eTrex Legend HCx de 12 canais.

Para determinar a acurácia dos mapas, foram calculados a exatidão global e o coeficiente de Kappa para cada uma das classificações realizadas. A exatidão Global foi calculada de acordo com Bishop *et al.* (1975) por meio da equação:

$$EG = \frac{A}{N} \times 100$$

Onde: EG = Exatidão Global; A = Acerto geral (Pontos amostrais com acerto); N = número de pontos amostrais.

O coeficiente Kappa (Cohen, 1960) é calculado a partir do uso de uma matriz de confusão. Esta, por sua vez, é gerada após a verificação dos resultados obtidos na classificação digital.

Após a conferência das imagens aéreas com os pontos, e de posse dos dados das fichas de campo, preencheu-se a matriz de confusão, onde foram associadas às ocorrências de acertos e erros da imagem classificada em relação à referência terrestre. O Coeficiente de Kappa pode ser obtido por meio da seguinte fórmula:

$$K = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Onde: K = Coeficiente Kappa de concordância; N = Número de observações (pontos amostrais); r = Número de linhas da matriz de erros; x_{ii} = Observações na linha i e coluna i; x_{i+} = Total marginal da linha i; x_{+i} = Total marginal da coluna i.

Os resultados do índice Kappa calculado para cada teste de classificação foram interpretados de acordo com Mangabeira *et al.* (2003) (Tabela 2).

Índice de Kappa (%)	Qualidade da estimativa
80 a 100	Excelente
60 a 80	Muito boa
40 a 60	Boa
20 a 40	Razoável
0 a 20	Ruim
< 0	Péssima

Tabela 1 Tabela para interpretação do índice kappa.
 Fonte: Mangabeira *et al.* (2003)

A partir dos mapas gerados calculou-se a área pertencente a cada classe de cobertura do solo para todos os testes de classificação. Em seguida, foi realizada análise de Cluster no programa estatístico *Paleontological Statistics-PAST* (Hammer *et al.*, 2003) a partir do método de distância euclidiana. O algoritmo utilizado foi grupo emparelhado, comparando as áreas de cada classificação. Essa rotina objetivou identificar o teste de classificação que mais se aproximava do mapa de classes de uso das terras gerado por fotointerpretação, considerado como referência.

3 Resultados e Discussão

O grau de similaridade adotado para gerar a segmentação determina a qualidade da mesma (Zhang, 2008). Para as imagens aéreas utilizadas, os parâmetros de *similaridade* e *área* usados para gerar as segmentações foram definidos por tentativa e erro. Segundo Ouyang *et al.* (2011) não existem critérios pré-estabelecidos ou experiências

sofisticadas para determinar os melhores parâmetros para segmentação.

Devido a grande quantidade de testes de classificação gerados, optou-se em detalhar o que apresentou melhor resultado no índice Kappa e exatidão global. Visualmente, a segmentação com valor de 20 de similaridade e 200 de área (Figura 3) representou o tratamento que, além de obter 85,18% no índice e exatidão global e 82,35% no índice kappa classificado como excelente.

Considerando que os resultados da pesquisa devam ser usados por responsáveis técnicos de planos de recuperação de áreas degradadas, considerou-se que a rotina de classificação mais apropriada deve ser a mais automatizada possível, reduzindo a necessidade de realizar uma edição nas imagens classificadas (pós-classificação). Será apresentada neste artigo, apenas a classificação que obteve o melhor resultado nas análises realizadas.

Os demais tratamentos com índice de similaridades menores que 20, apresentaram excessiva confusão entre os pixels, gerando muitos polígonos isolados dentro de grandes regiões. Em relação aos tratamentos com similaridade maiores que 20, houve classes que extrapolaram o limite da região a qual pertencia. Já as classificações pixel a pixel, os resultados de exatidão global e índice kappa, em geral, foram inferiores aos da classificação por região, com exceção da classificação supervisionada realizada no software ArcGis, cuja a validação foi classificada como muito boa, porém, houve muita confusão entre os pixel de agricultura e vegetação rasteira.

Ao analisar a referida segmentação verifica-se que ocorreu a delimitação com êxito de feições presentes na imagem aérea (Figura 3). No detalhe 1 nota-se que a estrada e a área agrícola foram bem delimitadas, assim como pequenas falhas presente na plantação. No detalhe 2 está em evidência parte da unidade demonstrativa de restauração ecológica (UDRE). Nessa área, há padrões de vegetação distintos devido as diferentes espécies plantadas na área por meio da técnica de restauração chamada muvuca. A referida área foi delimitada adequadamente, considerando as demandas para a realização de um plano de recuperação de área degradada (PRAD) e é possível verificar dois tipos de vegetação com coloração diferenciada (verde

claro e verde escuro), além do solo exposto foi bem delimitado tanto nas estradas como em pequenos polígonos presentes no interior da UDRE.

No detalhe 3 há uma estrada separando a UDRE (parte superior) de uma Área de Preservação Permanente (APP) desmatada e que atualmente encontra-se cercada para regeneração natural. Nessa última é possível identificar alguns indivíduos de porte arbóreo, solo exposto e uma vegetação rasteira seca. Nota-se que as diferentes feições presentes na área foram bem delimitadas na segmentação. No detalhe 4 a represa e as macrófitas presentes na mesma foram bem segmentadas, incluindo solo exposto, vegetação rasteira, mata e sombra. Já no detalhe 5 é possível verificar que a mata e as sobras

nela presente foram bem segmentadas assim como algumas áreas de vegetação rasteira (Figura 3).

Em termos gerais, a classe agricultura e as falhas presentes na plantação foram bem delimitadas. A classe UDRE (área em recuperação) foi bem classificada e por apresentar um conjunto de diferentes espécies, é possível identificar padrões semelhantes a algumas classes do seu entorno. Por esse motivo, essa classe possui regiões com vegetação rasteira, agricultura e pouca vegetação. As demais classes também foram classificadas com êxito e estão condizentes com a realidade da área de estudo (Figura 4).

Em trabalhos com imagens aéreas de alta resolução espacial, é comum se realizar a classificação

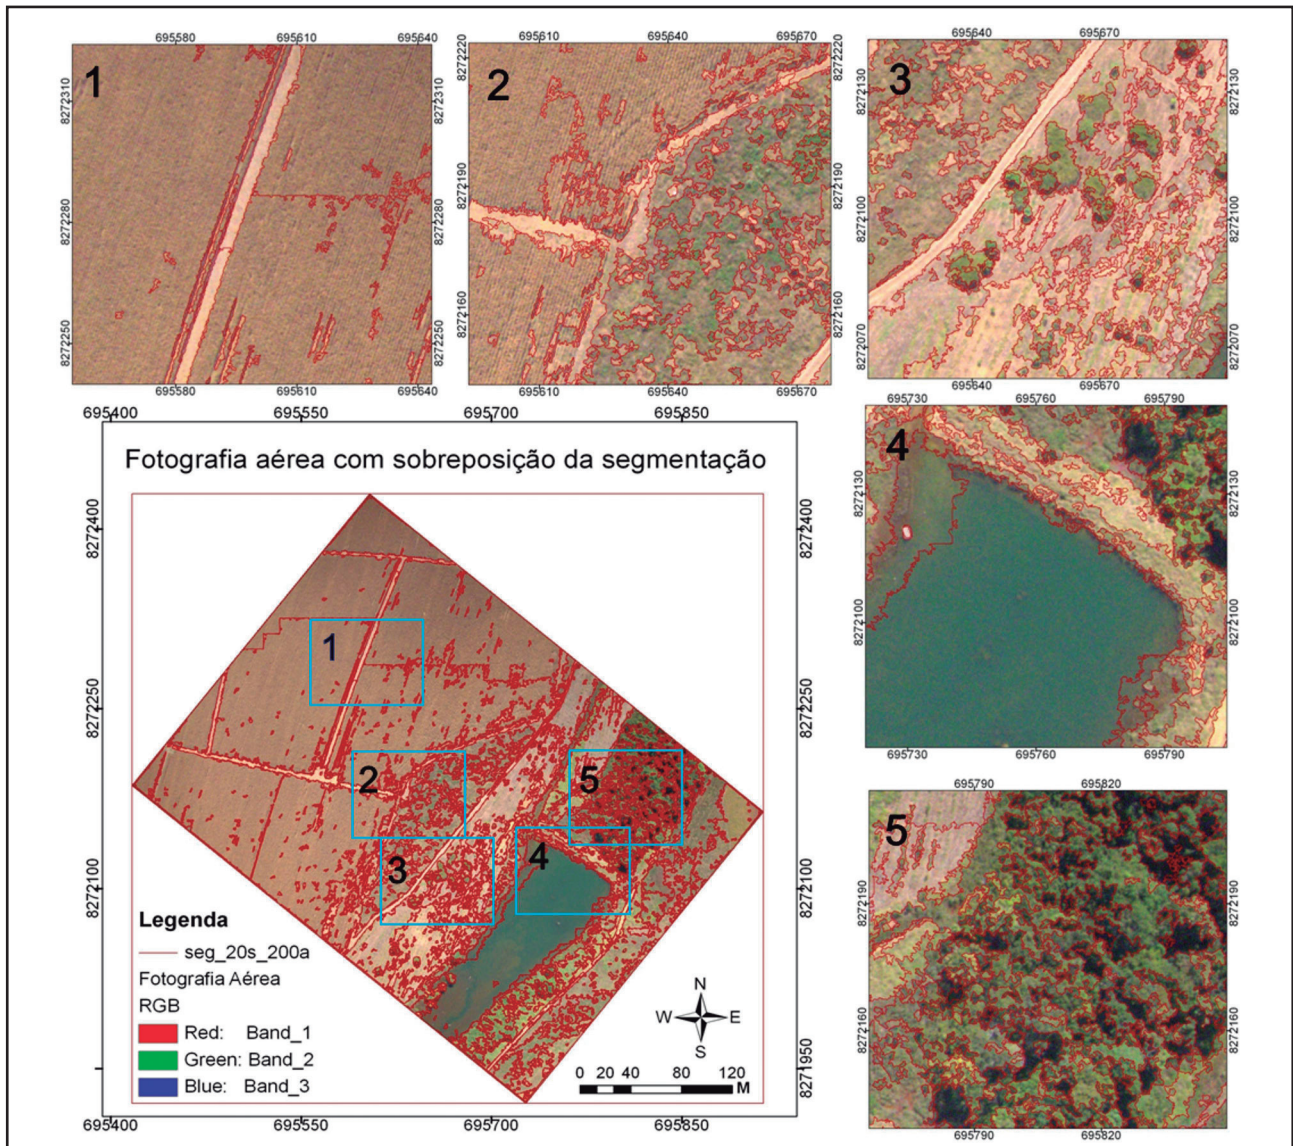


Figura 3 Segmentação com 20 de similaridade e 200 de área sobreposta à imagem aérea.

por fotointerpretação. Por esse motivo, foi realizada uma análise comparativa entre as classificações automáticas e a classificação por fotointerpretação (Figura 5). Vários trabalhos com imagens aéreas utilizam fotointerpretação para análise das imagens como é o caso de Ekstrand (1994), que estudou a saúde e vitalidade de uma floresta a partir de imagens aéreas com infravermelho. Disperati *et al.* (2007) aplicaram a técnica da “filtragem de locais máximas” para marcação do topo das copas de árvores e posterior contagem.

A classificação por fotointerpretação tende a exigir grande esforço humano, pois há imagens que requerem a geração de inúmeros polígonos em tamanhos diminutos. No entanto, essa prática é bastante adotada, devido às limitações na realização de classificações automáticas, pelo fato das imagens serem sintéticas e não multiespectrais. Isso impossibilita a realização da classificação digital das fotos aéreas, pois a maioria é de pequeno formato, ou seja, não possui bandas.

Para uma análise visual mais refinada, algumas classificações supervisionadas e não supervisionadas, foram comparadas, com a classificação derivada de fotointerpretação. Ao comparar as áreas das diversas classes de usos da

terra, em termos das classificações automáticas, com a classificação por fotointerpretação (Figura 5), nota-se maior semelhança entre a fotointerpretação e a classificação supervisionada por região com similaridade 20 e área 200 (Figura 6).

A análise de dendograma (Figura 7) mostra que a classificação por fotointerpretação e a classificação supervisionada por região com segmentação 20 e área 200, são estatisticamente semelhantes, evidenciando que essa classificação automática possui potencial para apresentar a mesma qualidade que a classificação por fotointerpretação, baseada na vetorização das classes do uso do solo.

Lian e Chen (2011) trabalharam com classificação orientada a objeto em imagens de satélites de alta resolução espacial e concluíram que a precisão da classificação está relacionada com a resolução, uma vez que a precisão diminui de SPOT (2,5m), SPOT (10m) para ASTER (15m).

Em relação às imagens aéreas de pequeno formato com alta resolução espacial, verifica-se que as mesmas, convencionalmente, são classificadas por meio de vetorização, como é o caso de Disperati & Oliveira Filho (2005) que trabalharam com delineamento de copas de árvores.

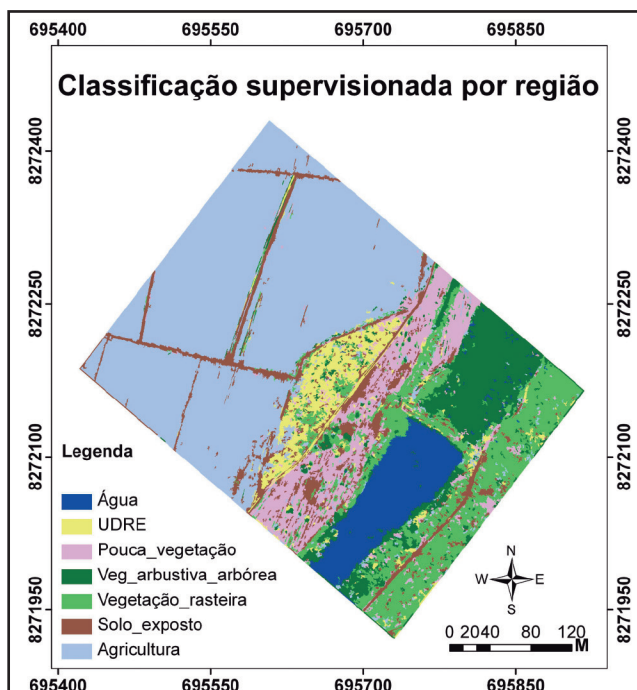


Figura 4 Segmentação com similaridade 20 e área 200 seguida de classificação supervisionada por região com o algoritmo Bhattacharya no SIG SPRING.

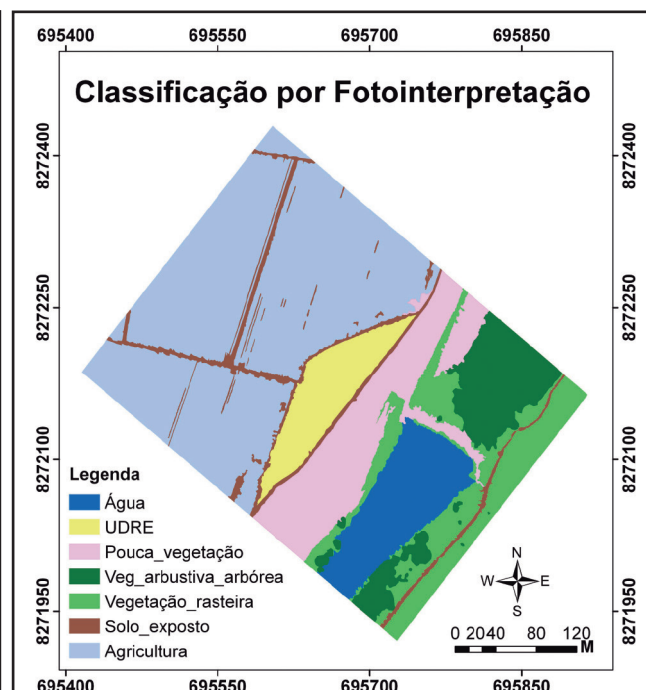
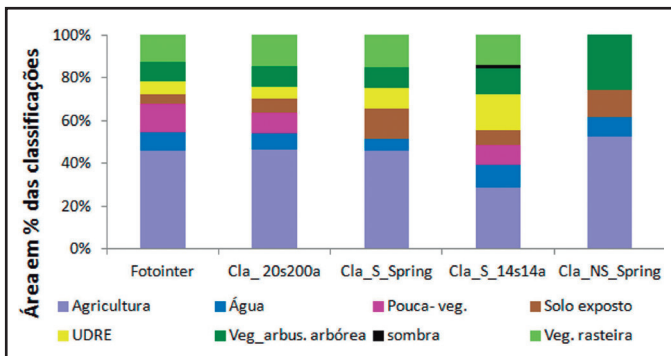
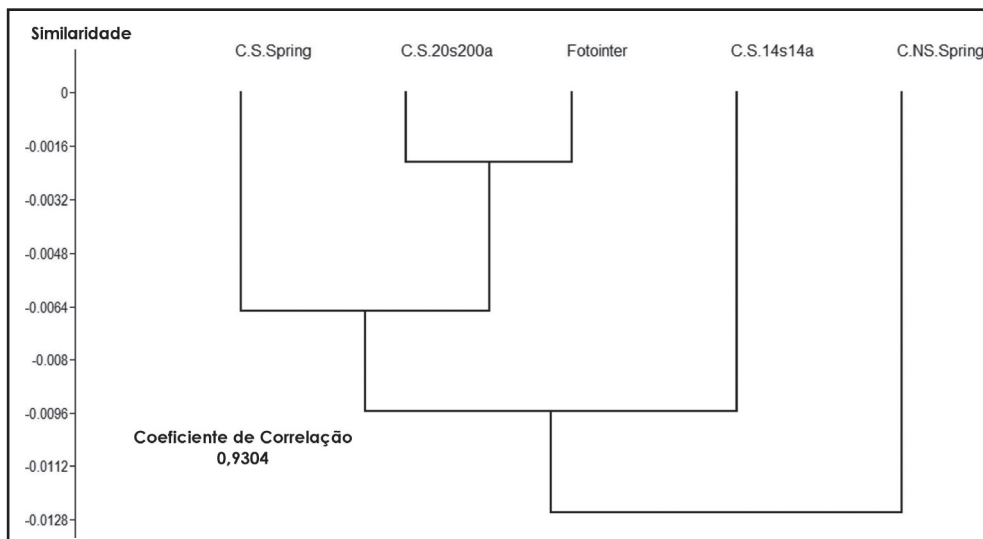


Figura 5 Classificação por fotointerpretação.



Legenda:
Fotointer = classificação por fotointerpretação;
Cla_20s200a = classificação supervisionada por região, tendo segmentação com similaridade 20 e área 200;
Cla_S_Spring = Classificação Supervisionada pixel a pixel no Spring;
Cla_S_14s14a = classificação supervisionada por região, tendo segmentação com similaridade 14 e área 14;
Cla_NS_Spring = Classificação pixel a pixel não supervisionada no Spring.

Figura 6 Comparação em porcentagem entre as áreas de cobertura do solo das classificações automáticas com a classificação por fotointerpretação.



Legenda:
C_S_Spring = Classificação Supervisionada pixel a pixel no Spring;
C.S_20s200a = classificação supervisionada por região, tendo segmentação com similaridade 20 e área 200;
Fotointer = classificação por fotointerpretação;
C_S_14s14a = classificação supervisionada por região, tendo segmentação com similaridade 14 e área 14;
C_NS_Spring = Classificação pixel a pixel não supervisionada no Spring.

Figura 7 Dendrograma mostrando a similaridade entre os diversos testes de classificação aplicados

O presente trabalho traz uma alternativa para realizar análises de forma automatizada, principalmente as relacionadas com a cobertura do solo e os resultados aqui obtidos são importantes sob diversos aspectos, pois podem aperfeiçoar trabalhos de pesquisa que envolvem mapeamentos de uso e ocupação das terras, numa escala de alto detalhe, como perícias ambientais, bem como, projetos técnicos que envolvem a detecção e monitoramento de áreas degradadas, como os planos de recuperação de áreas degradadas (PRAD), que podem ser um condicionante para a regularização ambiental de propriedades rurais no Brasil.

4 Considerações Finais

A classificação supervisionada em imagens de alta resolução obtidas por VANTs, utilizando classificadores automáticos por região no SIG SPRING, mostrou-se eficiente na delimitação dos principais alvos de interesse presentes na imagens aérea, evitando-se o trabalho de digitalização, baseado em fotointerpretação, pois, por muitas vezes, gera demanda de delimitação de pequenos e numerosos polígonos.

A classificação supervisionada por região (grau de similaridade 20 e área 20) apresentou eficácia na delimitação de uma unidade demonstrativa de restauração ecológica (UDRE), embora esta área esteja no início do processo de restauração. Essa técnica possibilitou diferenciar a UDRE da vegetação rasteira, bem como das demais feições presentes na área.

As imagens aéreas de alta resolução espacial possuem potencial para o mapeamento do padrão de uso e ocupação das terras, bem como, no monitoramento da eficácia da recuperação ambiental de áreas degradadas, podendo ser incorporada no roteiro metodológico de planos de recuperação de áreas degradadas (PRAD).

De acordo com dados governamentais, um terço da área total de Mato Grosso apresenta-se em estado de degradação. A Secretaria de Estado do Meio Ambiente de Mato Grosso identificou no Estado, aproximadamente um milhão e duzentos mil hectares de matas ciliares, e cerca de cem mil

hectares de reservas legais degradadas. Cerca de 690 propriedades rurais de Mato Grosso cadastradas na base de dados da SEMA-MT estão com o processo de recuperação (Plano de Recuperação de Área Degradada - PRAD) desenvolvido em desacordo com o pactuado nos Termos de Ajustamento de Condução (TACs).

Nesse contexto, os dados gerados pela presente pesquisa, podem trazer uma contribuição efetiva, não apenas para o mapeamento dos padrões de uso e ocupação das terras em escala espacial de alto detalhe, mas também, visando o aperfeiçoamento das técnicas de implantação e de monitoramento da eficácia do grau de regeneração de áreas submetidas à recuperação ambiental, o que contribui para o cumprimento do Código Florestal Brasileiro (Lei 12.651/2012), que estabelece a necessidade do Cadastro Ambiental Rural (CAR), para imóveis rurais.

4 Agradecimentos

Aos bolsistas PIBIC (CNPq) e Permanência (UFMT) do curso de Engenharia Agrícola e Ambiental (UFMT – Rondonópolis). A CAPES pela concessão de bolsa à primeira autora. Ao CNPq pelo apoio financeiro no âmbito de três projetos de pesquisa (Processos, 561923/2010-8, 310724/2011-2 e 305300/2012-1).

5 Referências

Bishop, Y.; Fienberg, S. & Holland, P. 1975. Discrete multivariate analysis: theory and practice. Cambridge, MIT. 575 p.

Bryson, M.; Reid, A.; Ramos, F. & Sukkarieh, S. 2010. Airborne vision-based mapping and classification of large farmland environments. *Journal of Field Robotics*, 27(5): 632-655.

Checoli, C. H. B. 2012. *Gestão participativa da microbacia hidrográfica da Cabeceira do Rio São Lourenço: definição e implantação de diferentes tecnologias para realização do PRAD, Campo Verde – MT*. Programa de Pós-graduação em Recursos Hídricos, Universidade Federal de Mato Grosso, Dissertação de Mestrado, 83 p.

Cohen, J. 1960. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1): 37-46.

Córcoles, J.I.; Ortega, J.F.; Hernández, D. & Moreno, M.A. 2013. Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle. *Biosystems Engineering*, 115(1): 31-42.

Disperati, A.A.; Santos, J.R.; Oliveira Filho, P.C. & Neeff, T. 2007. Aplicação da técnica “filtragem de locais máximas” em fotografia aérea digital para a contagem de copas em reflorestamento de *Pinus elliottii*. *Scientia Forestalis*, 76(1): 45-55.

Disperati, A.A. & Oliveira Filho, P.C. 2005. Delineamento de copas de árvores em fotografias aéreas de alta resolução, através de suas sombras periféricas: estudo de caso na Floresta Ombrófila Mista. *Revista Árvore*, 29(2): 195-202.

Ekstrand, S. 1994. Close range forest defoliation effects of traffic emissions assessed using aerial photography. *Science of the total Environment*, 146-147(1): 149-155.

ESRI. 2010. Environmental Systems Research Institute. ArcMap. Versão 9.3.1, Estados Unidos. CD-ROM. 2010.

Felfili, J.M.; Nogueira, P.E.; Silva Júnior, M.C.; Marimon, B.S. & Delitti, W.B.C. 2002. Composição florística e fitossociologia do cerrado sentido restrito no município de Água Boa, MT. *Acta Botanica Brasileira*, 16(1): 103-112.

Gonzales, R. C. & Wintz, P. 1987. *Digital image processing*. Reading, Mass: Addison-Wesley. 431 p.

Google Earth-Mapas. Disponível em: <<http://earth.google.com/intl/pt/license.html>>. Acesso em: 15 de Ago. 2011.

Hammer, O.; Harper, D.A.T. & Ryan, P.D. Paleontological Statistics- PAST. 2003. Version 1.18. Disponível em: <<http://folk.uio.no/ohammer/past>> acesso em: 22 de Agosto de 2012.

INPE – Instituto Nacional de Pesquisas Espaciais. 2012. SPRING: Sistema de Processamento de Informações Georeferenciadas. Versão: 4.3 software livre. São José dos Campos: DPI/INPE, 2012. Disponível em <www.dpi.inpe.br/spring/>. Acesso em 13 Mai. 2012.

Leite, M.E.; Leite, M.R. & Clemente, C.M.S. 2010. O uso do solo e o conflito por água no alto rio Riachão – norte de minas gerais: uma análise Auxiliada pelas geotecnologias. *Revista Geográfica Acadêmica*, 4(1): 46 – 55.

Lian, L. & Chen, J. 2011. Research on segmentation scale of multi-resources remote sensing data based on object-oriented. *Procedia Earth and Planetary Science*, 2(1): 352-357.

Lima Neto, E.M.; Biondi, D.; Araki, H. & Bobrowski, R. 2012. Fotografias aéreas para mensuração da área de copa das árvores de ruas de Curitiba-PR. *Revista Floresta*, 42 (3): 577-586.

Loverde-Oliveira, S.M & Nascimento, F.A.S. 2004. *Ecologia e História do Vale do São Lourenço*. Rondonópolis, 57p.

Mangabeira, J.A.C.; Azevedo, E.C. & Lamparelli, R.A.C. 2003. Avaliação do levantamento de uso das terras por imagens de satélite de alta e média resolução espacial. Campinas: Embrapa. *Comunicado técnico*, 11: 1-15.

Martins, S.V. 2001. *Recuperação de Matas Ciliares*. Viçosa, Aprenda Fácil. 146 p.

Moigne, J.L. & Tilton, J.C. 1995. Refining image segmentation by integration of edge and region data. *Geoscience and Remote Sensing, IEEE Transactions on*, 33(3): 605-615.

Morgan, J.L.; Gergel, S.E. & Coops, N.C. 2010. Aerial photography: a rapidly evolving tool for ecological management. *BioScience*, 60(1): 47-59.

Ouyang, Z.; Zhang, M.; Xie, X.; Shen, Q.; Guo, H. & Zhao, B. 2011. A comparison of pixel-based and object-oriented approaches to VHR imagery for mapping saltmarsh plants. *Ecological informatics*, 6(2): 136-146.

Paranhos Filho, A.C.; Lastoria, G. & Torres, T.G. 2008. *Sensoriamento Remoto Ambiental Aplicado: introdução às geotecnologias*. Campo Grande, UFMS. 198 p.

Perea, A.J.; Meroño, J.E.; Aguilera, M. J. & Cruz, J.L. 2010. Land-cover classification with an expert classification algorithm using digital aerial photographs. *South*

- African Journal of Science*, 106(5-6): 92-97.
- Ribeiro, J.F. & Walter, B.M.T. 1998. Fitofisionomias do bioma cerrado. In: SANO, S.M. & ALMEIDA, S.P. (ed.). *Cerrado: ambiente e flora*. Editora EMBRAPA – CPAC, p. 89-166.
- Secretaria de Estado do Meio Ambiente de Mato Grosso (SEMA). 2010. *Relatório de Monitoramento da Qualidade da Água da Região Hidrográfica do Paraguai – 2007 a 2009*. Cuiabá, MT, 110p.
- Secretaria de Estado do Meio Ambiente de Mato Grosso (SEMA). 2010. Imagens SPOT de 2007. Rondonópolis. Disponível em: <<http://www.sema.mt.gov.br/>>. Acesso em: 15 Mai. 2010.
- Softonic International S. L. Able RAWer. Software Livre. Barcelona. Disponível em: <<http://able-rawer.softonic.com.br/>>. Acesso em 20 Jun. 2011.
- Spatial Ecology. *Hawth's Analysis Tools*. Extensão para software ArcGis. Disponível em: <<http://www.spatial ecology.com/htools/download.php>>. Acesso em 15 fev. 2012.
- Rudorff, B.F.T.; Berka, L.M.S.; Moreira, M.A.; Duarte, V.; Xavier, A.C.; Rosa, V.G.C. & Shimabukuro, Y.E. 2005. Imagens de satélite no mapeamento e estimativa de área de cana-de-açúcar em São Paulo: ano-safra 2003/04. *Agricultura em São Paulo*, 52(1): 21-39.
- Xiang, H. & Tian, L. 2011. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). *Biosystems engineering*, 108 (2): 174-190.
- Zhang, H.; Fritts, J. E. & Goldman, S.A. 2008. Image segmentation evaluation: A survey of unsupervised methods. *Computer vision and image understanding*, 110(2): 260-280.
- Zhou, W. & Troy, A. 2008. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. *International Journal of Remote Sensing*, 29(11): 3119-3135.