

Classificação de Imagens Adquiridas por Sensores Embarcados em Satélite Orbital e Aeronaves Remotamente Pilotadas por meio de Árvores de Decisão

Eduardo Souza de Oliveira¹, Elcio Hideiti Shiguemori², Camila S. Anjos³

⁽¹⁾Faculdade de Tecnologia de Jacareí – FATEC Jacareí – Geoprocessamento, Jacareí - SP

⁽²⁾⁽³⁾Instituto de Estudos Avançados (IEAv) – Divisão de Geo-inteligência, São José dos Campos – SP

Resumo – O presente trabalho utiliza classificadores não-paramétricos baseados em árvores de decisão com o objetivo de classificar detalhadamente os diversos materiais de cobertura do solo urbano. As imagens orbitais e imagens obtidas por aeronaves remotamente pilotadas (ARP) utilizadas possuem alta resolução espacial, o que justifica a escolha de tais classificadores que possibilitam lidar com massiva quantidade de dados de entrada, além de serem pouco explorados no âmbito do Sensoriamento Remoto. Uma análise comparativa entre os conjuntos de dados é realizada ao fim do trabalho para verificar se ambos os sensores são capazes de discriminar com detalhes os materiais presentes no ambiente urbano.

Palavras-Chave – Aeronaves Remotamente Pilotadas, Árvore de Decisão, Classificação de Imagens.

I. INTRODUÇÃO

A origem do sensoriamento remoto nos anos de 1960 deve-se ao espetacular desenvolvimento da área espacial nesses anos, que ficou conhecida como a década da corrida espacial. Foi nesse período que se viu o mais rápido desenvolvimento de foguetes lançadores de satélites, que possibilitou colocar no espaço satélites artificiais para várias finalidades [1].

A melhoria na resolução espacial dos sensores foi um grande avanço no sentido de obter informações mais precisas dos alvos. Na classificação de dados de sensoriamento remoto de áreas urbanas, a identificação de objetos relativamente pequenos é importante. Por conseguinte, uma elevada resolução espacial da imagem é necessária para a classificação precisa [2].

De acordo com [3], os ambientes urbanos representam uma das mais desafiadoras áreas de análise para o sensoriamento remoto, pois sua diversidade espectral excede em muito a de outros ambientes antropizados e naturais. Os materiais presentes no ambiente urbano apresentam alta diversidade espacial e espectral, pois incluem uma ampla gama de telhados, estradas, calçadas, submetidos a intemperismo e de diversas idades, qualidades e composições químicas, entre outras minúcias [4].

No presente trabalho foram utilizados classificadores não-paramétricos baseados em árvores de decisão, pois tais classificadores são capazes de lidar com massiva quantidade de dados de entrada, sendo ainda, pouco explorados neste âmbito do sensoriamento remoto. O objetivo foi classificar detalhadamente os diversos materiais de cobertura do solo urbano presente na área de estudo tais como pavimentações

viária e não-viária, vegetação, corpos d'água, solo exposto e materiais de recobrimento de edificações (lajes, telhados e coberturas em geral) utilizando classificadores não paramétricos baseados em árvores de decisão.

II. METODOLOGIA

A área de estudo está localizada dentro do campus da Universidade do Vale do Paraíba (UNIVAP) na cidade de São José dos Campos-SP. O local foi escolhido devido à disponibilidade de dados e a proximidade para a realização do trabalho de campo. Foram utilizadas no presente trabalho, duas imagens, sendo uma imagem orbital e um mosaico gerado a partir de um levantamento por Aeronave Remotamente Pilotada (ARP).

A imagem orbital do satélite GeosEye-1 (Fig. 1) tem resolução espacial de 2,0 m para as bandas azul, verde, vermelho e infravermelho próximo e 0,5 m para a banda pancromática com data de aquisição de 29/11/2011.

O Mosaico ARP (Fig. 2), por sua vez, é fruto de um trabalho organizado por pesquisadores do projeto PITER-IEAv realizado em 18/06/2016 com ARP Phantom-4 que possui uma câmera FC 330 de 12 MPixels RGB e resolução espacial de 0,02097 m. O voo foi planejado para recobrir 15 hectares com 50 metros de altura média, tendo 60% de sobreposição lateral e 80% de sobreposição longitudinal [5].



Fig. 1. Imagem GeosEye. A pequena área destacada em vermelho representa a área de estudo.

Para trabalhar com imagens oriundas de fontes distintas, foi realizado um Recorte da Imagem GeosEye tendo como base o Mosaico das imagens obtidas pela ARP. Após o recorte da Imagem GeoEye para as bandas multiespectrais e a

banda pancromática, as novas imagens foram submetidas ao processo de fusão de imagens.



Fig. 2. Mosaico de Imagens obtidas por ARP.

A técnica de fusão de imagens tem como principal objetivo aumentar a resolução espacial das imagens multiespectrais com base na imagem pancromática que possui melhor resolução espacial [1]. A partir de testes, o método de PCSS (*Principal Component Spectral Sharpening*) se mostrou o mais indicado para o processo de Fusão da cena GeoEye.

A partir do processo de Fusão que gerou novas quatro imagens multiespectrais GeoEye com melhor resolução espacial de 0,5 m, foi possível gerar uma composição colorida de alta resolução espacial (Fig. 3).



Fig. 3. Imagem multiespectral fusionada.

A imagem fusionada aplicou-se o processo de reamostragem para adequá-la a resolução espacial do mosaico ARP. O processo de reamostragem consistiu em redimensionar o tamanho do pixel da imagem de satélite de acordo com o tamanho do pixel da imagem do mosaico ARP.

Após este procedimento, foi realizado o processo de registro do mosaico tendo como base a imagem orbital. O registro é o processo que envolve a superposição de uma mesma cena que aparece em duas ou mais imagens, de forma que os pontos correspondentes nessas imagens coincidam espacialmente [1]. No presente trabalho foram realizados

diversos testes e optou-se por utilizar pontos automáticos e pontos manuais, chegando assim a um erro controlado de RMS (*Root Mean Square*) de aproximadamente 20 pixels.

Após as etapas de pré-processamento das imagens descritas acima, foi realizado o trabalho de campo. Nesta etapa foram identificadas todas as feições encontradas nas imagens, e realizado o levantamento dos principais materiais constituintes destas feições. Foi elaborada uma planilha de campo para anotação de observações e realizado o registro fotográfico das feições identificadas nas imagens (Fig. 4).



Fig. 4. Registro fotográfico das feições.

Após a realização do trabalho de campo com o registro fotográfico das feições, todos os materiais presentes na área de estudo foram separados em 17 Classes que compõem o Mapa de Classificação das imagens em estudo (Fig. 5). As classes foram definidas levando-se em conta as principais feições e materiais encontrados na área de estudo.

■	Bloquete
■	Bloquete_Azul
■	Bloquete_Branco
■	Coberturas_Cerâmicas
■	Coberturas_Concreto
■	Coberturas_Diversas
■	Coberturas_Metálicas
■	Coberturas_Metálicas_Ferrugem
■	Concreto
■	Concreto_Branco
■	Fibrocimento
■	Manta_Asfáltica_Aluminizada
■	Solo_Exposto
■	Sombra
■	Vegetação_Arbórea
■	Vegetação_Rasteira
■	Água

Fig.5 Legenda de Classes.

Após a definição das classes, deu-se início à etapa de segmentação de imagens. Nesta etapa foram realizados diversos testes no intuito de se obter a melhor segmentação para cada imagem, onde os segmentos não fossem tão diminutos ao tamanho de um pixel, nem muito grandes a

ponto de abarcarem em si classes diferentes. Esta etapa foi realizada utilizando o software eCognition. Dessa forma, para a Imagem GeoEye (Fig. 6) utilizou-se os seguintes parâmetros de segmentação: Escala: 150, Forma: 0.8, Compacidade: 0.8 e Diferença Espectral: 30. Já para a imagem ARP (Fig. 7), foram utilizados os seguintes parâmetros de segmentação: Escala: 50, Forma: 0.6, Compacidade: 0.6 e Diferença Espectral: 5.



Fig. 6. Segmentação Imagem Geoeye-1.



Fig. 7. Segmentação Imagem ARP.

Tendo sido realizada a segmentação das imagens, iniciou-se a etapa de seleção de amostras para o uso dos algoritmos de classificação. Para a seleção das amostras levou-se em conta o universo de segmentos para ambas as imagens, dessa forma foi coletado um número maior de amostras para a imagem ARP com relação a imagem orbital. De um universo de 39.143 segmentos gerados para a imagem ARP, foram selecionadas 544 amostras das 17 classes estabelecidas. Já para a imagem orbital, de 24.683 segmentos gerados, foram selecionadas 388 amostras.

Após a seleção de amostras de acordo com as classes definidas anteriormente, o conjunto de dados foi classificado no software livre Weka (*Waikato Environment for Knowledge Analysis*) que possui uma biblioteca de algoritmos de aprendizagem de máquinas para tarefas de mineração de dados, ou pode ser ainda utilizado

implementando algoritmos próprios que são chamados por meio de um código Java. Na presente pesquisa foram utilizados os algoritmos C4.5 [6] e Random Forest [7] que geram árvores aleatórias de decisão baseadas nas variáveis dos arquivos de amostras.

Para a classificação do conjunto de dados baseado nos arquivos de amostras foram utilizadas as seguintes variáveis: Máxima diferença; Média espectral; Desvio Padrão e Brightness (brilho médio). A partir dessas variáveis os algoritmos C4.5 e Random Forest (RF) geraram árvores de decisão que produziram a classificação de todo conjunto de dados.

Após a classificação de todo conjunto de dados por meio dos algoritmos acima destacados utilizando o minerador de dados WEKA, as informações de classificação dos segmentos foram transferidas para a tabela de atributos do arquivo em formato shapefile e então o novo arquivo foi visualizado no software QGis.

III. RESULTADOS E DISCUSSÃO

As etapas de Recorte, Fusão, Reamostragem e Registro das imagens permitiram compreender a importância do pré-processamento de imagens no processo de classificação, uma vez que se trata de fontes de dados distintas. Desta forma, conhecendo os procedimentos, os erros e os parâmetros utilizados em cada etapa do Processamento Digital de Imagens (PDI), será possível realizar estatísticas de comparação entre as imagens.

O trabalho de campo permitiu realizar o registro das principais feições presentes na área de estudo bem como identificar os materiais que geraram dúvidas em uma primeira análise e que puderam ser solucionadas com o trabalho in loco.

O processo de segmentação das imagens permitiu avaliar quais os melhores parâmetros para cada imagem levando em consideração as resoluções espaciais e o tamanho dos segmentos gerados, de forma a obter segmentos que melhor se aplicam ao método de classificação empregado.

Com relação aos algoritmos empregados na metodologia (C4.5 e Random Forest) avaliou-se que o algoritmo Random Forest apresentou melhores resultados do ponto de vista estatístico se comparado ao método utilizando o algoritmo C4.5. Isso se dá pelo fato do método Random Forest não gerar apenas uma, mas uma floresta de árvores aleatórias e comparar os resultados dessas árvores, classificando assim as feições em estudo, já o algoritmo C4.5 gera apenas uma árvore aleatória de decisão, sendo assim o algoritmo Random Forest possui melhor acurácia, porém o C4.5 possui maior rapidez na mineração de dados [8].

Para a imagem ARP, o algoritmo C4.5 gerou um mapa de classificação (Fig. 8) com Exatidão Global de 69,8292% e Índice Kappa de 0,6651. Já o algoritmo Random Forest gerou um mapa de classificação (Fig. 9) com Exatidão Global de 78,7476% e Índice Kappa de 0,7632



Fig. 8. Mapa de Classificação da imagem ARP algoritmo C4.5.



Fig. 9. Mapa de Classificação da imagem ARP algoritmo Random Forest.

Para a imagem GeoEye, o algoritmo C4.5 gerou um mapa de classificação (Fig. 10) com Exatidão Global de 60,567% e Índice Kappa de 0,5675. Com o algoritmo Random Forest gerou um mapa de classificação (Fig. 11) com Exatidão Global de 67,268% e Índice Kappa de 0,6403.



Fig.10. Mapa de Classificação da imagem Geoeye algoritmo C4.5.



Fig.11. Mapa de Classificação da imagem Geoeye algoritmo Random Forest.

A relação entre o número de amostras (nA) dividido pelo total de segmentos (nS) classificados por classe para cada algoritmo se apresentam na Tabela 1.

TABELA 1. PORCENTAGEM DE AMOSTRAS POR CLASSE nA/nS (%)

Classes	ARP		Geoeye	
	nA/nS C4.5 (%)	nA/nS RF (%)	nA/nS C4.5 (%)	nA/nS RF (%)
Bloquete	3,86	3,95	2,17	2,56
Bloquete_Azul	6,38	14,63	0,00	0,00
Bloquete_Branco	9,47	14,29	3,76	7,46
Coberturas_Ceramicas	1,05	0,88	1,27	1,78
Coberturas_Concreto	1,06	1,15	1,03	1,26
Coberturas_Diversas	1,55	1,34	3,54	2,25
Coberturas_Metálicas	4,04	6,25	6,69	9,95
Coberturas_Metálicas_Ferrugem	1,28	20,59	0,00	0,00
Concreto	2,42	2,63	1,41	1,29
Concreto_Branco	9,09	9,23	2,26	2,34
Fibrocimento	33,33	50,00	13,73	10,45
Manta_Asfáltica_Aluminizada	9,02	12,63	5,15	9,48
Solo_Exposto	1,65	1,77	1,70	1,69
Sombra	1,67	1,38	3,16	3,23
Vegetação_Arbórea	0,64	0,63	1,40	1,13
Vegetação_Rasteira	1,12	1,42	0,61	0,63
Água	0,00	0,00	23,33	23,33
Total	1,35		1,57	

Os valores de Exatidão Global e Índice Kappa para os dois conjuntos de dados são apresentados respectivamente nas figuras 12 e 13.

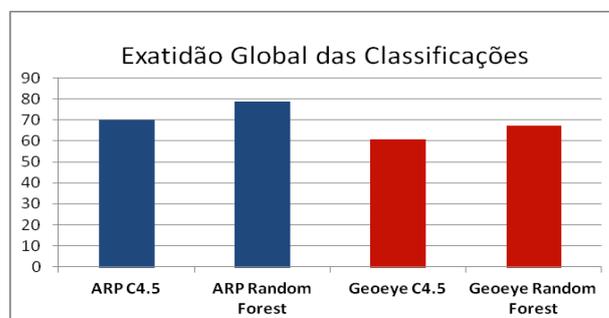


Fig. 12. Exatidão Global (%) das classificações ARP (azul) e GeoEye (vermelho) com os métodos C4.5 e RF.

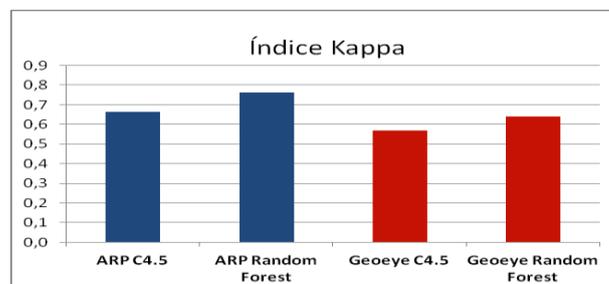


Fig. 13. Índice Kappa das classificações ARP (azul) e GeoEye (vermelho) com os métodos C4.5 e RF.

A seleção das amostras e a classificação das imagens utilizando os classificadores C4.5 e Random Forest permitiu reconhecer esse tipo de classificação não-paramétrica baseada em árvores de decisão como uma ferramenta bastante eficaz para a classificação de imagens uma vez que conseguiu chegar a valores de acerto de aproximadamente 70 % para a imagem Geoeye e aproximadamente 80% para a imagem ARP, ambas com o classificador Random Forest. Vale ressaltar que esta análise estatística foi feita com base na informação amostral e não para todos os segmentos classificados.

IV. CONCLUSÕES

Os métodos não-paramétricos baseados em árvore de decisão ainda são pouco explorados no Processamento Digital de Imagens. Tais classificadores apresentam grandes vantagens, pois podem lidar com uma quantidade massiva de dados. O uso de classificadores não-paramétricos baseados em árvore de decisão, aplicados a fontes de dados distintas (Imagem GeoEye e Imagem ARP) apresentou bons resultados quanto a análise quantitativa de acertos nas classificações obtidas pelos dois algoritmos implementados (C4.5 e Random Forest).

De acordo com a Exatidão Global e Índice Kappa o algoritmo Random Forest apresentou melhores resultados em ambos os conjuntos de dados quando comparado ao C4.5. Da mesma forma a Exatidão Global e Índice Kappa das classificações geradas pelas imagens ARP apresentaram melhores resultados em ambos os métodos quando comparado as classificações das imagens GeoEye.

Para estudos futuros sugere-se a produção de um mapa de verdade de campo baseado na identificação das feições in loco para que se possa comparar não apenas os dados amostrais, mas todo o conjunto de dados classificados pela metodologia apresentada na presente pesquisa.

REFERÊNCIAS

- [1] P. R. Meneses, T.Almeida. Introdução ao processamento de imagens de sensoriamento remoto. Brasília: UNB, 2012, 266p.
- [2] F. Melgani, L.Bruzzone. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, v. 42, n. 8, p. 1778-1790, 2004.
- [3] M. Herold, E.M. Gardner, D.A. Roberts. Spectral resolution requirements for mapping urban areas. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, p. 1907-1919, 2003.
- [4] C. S. Anjos Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos. Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, 2016.
- [5] F.C. Nogueira, L. Roberto, T.S. Körting, E.H. Shiguemori. Accuracy analysis of orthomosaic and DSM produced from sensors aboard UAV. *Simpósio Brasileiro de Sensoriamento Remoto*, Santos – SP, 2017.
- [6] R. Quinlan. C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, San Mateo, CA, 1993.
- [7] L. Breiman. Random forests. *Machine Learning*, v. 45, n. 1, pp. 5-32, 2001.
- [8] C.D.C.Lorenzetti, A.Teloken. Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forest e J48 na tomada de Decisão. II Simpósio de Pesquisa e Desenvolvimento em Computação, Cruz Alta – RS, 2016.