

PIXELS INDIVIDUAIS TRATADOS COMO OBJETOS PARA A CLASSIFICAÇÃO DA COBERTURA DA TERRA: INTEGRAÇÃO ENTRE GEOBIA E MINERAÇÃO DE DADOS GEOGRÁFICOS NA REGIÃO METROPOLITANA DO RIO DE JANEIRO (RMRJ)

INDIVIDUALS PIXELS TREATED AS OBJECTS FOR THE LAND COVER CLASSIFICATION: INTEGRATION BETWEEN GEOBIA AND GEOGRAPHIC DATA MINING IN THE METROPOLITAN REGION OF RIO DE JANEIRO (RMRJ)

Marcus Vinícius Alves de Carvalho
UFF - IGEO – POSGEO

UFRJ - CCMN / IGEO - Laboratório ESPAÇO: Sensoriamento Remoto e Estudos Ambientais
marcus.br@gmail.com

Gabriella Ferreira da Silva

UFRJ - CCMN / IGEO - Laboratório ESPAÇO: Sensoriamento Remoto e Estudos Ambientais
gabriella.geoufrj@gmail.com

Carla Bernadete Madureira Cruz

UFRJ - CCMN / IGEO - Laboratório ESPAÇO: Sensoriamento Remoto e Estudos Ambientais
carlamad@gmail.com

Enviado em 31/10/2018 e aceito para publicação em 01/12/2018

DOI: 10.12957/tamoios.2018.38099

RESUMO

Os mapeamentos temáticos constituem uma fonte relevante de informação para as mais variadas áreas de conhecimento, uma vez que auxiliam no planejamento e na tomada de decisões eficazes. A produção cartográfica foi consideravelmente revolucionada pelos avanços no Processamento Digital de Imagens (PDI) de Sensores Remotos, pois auxiliam tanto na elaboração quanto na atualização dos mapas de forma mais ágil e com custos reduzidos. Nessa perspectiva, o objetivo deste trabalho é avaliar a adoção de pixels individuais como “objetos” para a classificação da cobertura da terra na Região Metropolitana do Rio de Janeiro através da integração entre GEOBIA e Mineração de Dados Geográficos, e tendo como insumos os índices espectrais (NDVI e NDWI) e imagens transformadas (PCA, IHS e TasseledCap) provenientes dos dados OLI / LANDSAT-8. Estes, por sua vez, apresentam moderada resolução espacial, que é afetada pela questão da Mistura Espectral. Como resultado, o mapa temático de cobertura do solo alcançou alta precisão devido ao Índice Kappa de 0,871 e a percepção de que os atributos que mais auxiliaram na classificação foram aqueles provenientes da Transformação TasseledCap.

Palavras-chave: Sensoriamento Remoto, Pixels Individuais, Objetos, Mineração de Dados Geográficos.

ABSTRACT

Thematic mappings are a relevant source of information for the most varied areas of knowledge, assisting in effective planning and decision making. Cartographic production has been considerably revolutionized by the advances in Digital Image Processing (PDI) of remote sensors, as they help both the elaboration and updating of the maps in a more agile and with reduced costs. In this perspective, the objective of this work is to evaluate the adoption of individual pixels as “objects” for the classification of land cover in the Metropolitan Region of Rio de Janeiro through the integration between GEOBIA and Geographic Data Mining, and using as inputs the spectral indexes (NDVI and NDWI) and transformed images (PCA, IHS and TasseledCap) from OLI / LANDSAT-8 data. These, in turn, present moderate spatial resolution, which is affected by the Spectral Mixture. As a result, the land cover map reached high precision due to the Kappa Index of 0.871 and the perception that the attributes that most assisted in the classification were those from the TasseledCap Transformation.

Keywords: Remote Sensing, Individuals Pixels, Objects, Geographic Data Mining.

INTRODUÇÃO

A importância do Sensoriamento Remoto está no fato de que este aparato tecnológico consiste atualmente na maior fonte de dados para a realização e atualização de mapeamentos, sobretudo em países carentes de informações cartográficas atualizadas, como é o caso do Brasil (SOARES FILHO, 2000). A partir dos dados provenientes dos sensores remotos são extraídas informações atualizadas e até históricas num curto período de tempo e a baixo ou nenhum custo para a tomada de decisão pelos gestores e planejadores territoriais. A elaboração dos mapas temáticos, relevantes fontes de informação para as Geociências e outras mais áreas do conhecimento, foi consideravelmente revolucionada pelos avanços na área do Processamento Digital de Imagens (PDI). Atualmente, entre os diversos sistemas utilizados em PDI, destacamos aqueles que fazem uso da abordagem de classificação digital chamada de Análise de Imagem Baseada em Objetos Geográficos (GEOBIA). Nela o conceito de objeto é de suma importância, uma vez que, parte-se do princípio de que a informação semântica necessária para a interpretação de uma imagem não está presente apenas no pixel, e sim em objetos da imagem e nas relações existentes entre eles. Todavia, ocorre que em sensores de média e baixa resolução espacial um elemento da imagem (correspondente a um pixel) pode incluir mais de um tipo de cobertura da terra, caracterizando assim a mistura espectral. Desta forma, a radiância detectada da cena é a integração de todos os objetos, denominados componentes da mistura, contidos no elemento de cena (INPE, 2012). Sabe-se que outro considerável desafio em PDI refere-se à questão da qualidade das segmentações (divisão da cena em regiões compostas por conjuntos de pixels contíguos que se espalham bidirecionalmente e que apresentam uniformidade). Sobre isto, Araújo (2006) destaca que os cuidados com a segmentação da imagem são necessários, uma vez que, o resultado desta etapa repercute tanto positivamente quanto negativamente nas posteriores. Assim, sendo, neste trabalho avaliou-se o potencial da classificação da cobertura da terra ser realizada através de objetos que representassem exatamente os pixels de forma individual (isto é, os pixels não agrupados em segmentos) em imagens orbitais de média resolução espacial, justamente por serem afetadas pela mistura espectral. Por sua vez, em relação ao processo de classificação adotou-se a Mineração de Dados Geográficos (Descoberta de Padrões), devido neste trabalho ter sido avaliado também o potencial dos índices espectrais (álgebra de bandas) e imagens transformadas (síntese das bandas) para destacar os objetos presentes na cobertura da terra. Isto, porque em sistemas que adotam GEOBIA têm-se os desafios da busca pela seleção dos “melhores” atributos (espectrais, texturais, relacionais, contextuais, geométricos, entre outros, disponíveis em relevante quantidade nesses sistemas), respectivos limiares e a hierarquia das classes e processos. Neste contexto, a Mineração de Dados é um importante instrumento na elaboração de mapas temáticos, devido nela serem aplicados algoritmos específicos que atendem ao desenvolvimento de métodos e técnicas para “compreender” e extrair padrões em grandes quantidades de dados. Os recursos disponíveis nesses algoritmos envolvem técnicas de estatística, recuperação de informação, inteligência artificial e reconhecimento de padrões. Por sua vez, a área de estudo correspondeu à Região Metropolitana do Rio de Janeiro (RMRJ), que é composta por 21 municípios fluminenses e, se caracteriza por ser a segunda maior área metropolitana do Brasil, terceira da América do Sul e 20ª maior do mundo, de acordo com o Censo 2010 (IBGE, 2010), e ainda pela diversidade e complexidade de cobertura da terra nela presente.

METODOLOGIA

Na Figura 1 são apresentadas as etapas que compuseram a metodologia deste trabalho.

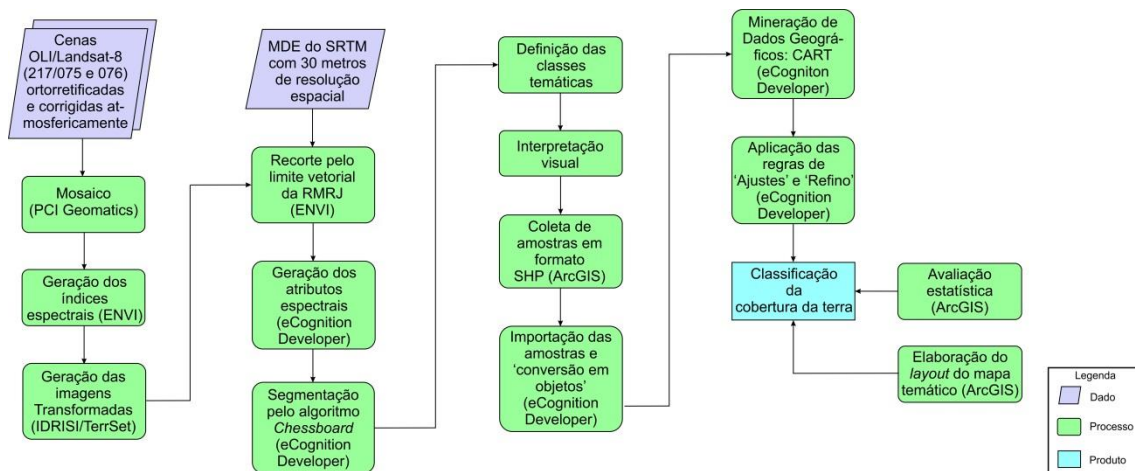


Figura 1. Fluxograma metodológico.

Para a realização deste trabalho foram selecionadas duas cenas do sensor OLI (Operational Land Imager) do satélite LANDSAT-8 correspondentes à órbita 217 e pontos 076 e 075, ambas adquiridas em 14/09/2017. Vale destacar que tais imagens já foram disponibilizadas ortoretificadas e corrigidas atmosféricamente (ao nível de refletância de superfície) pelo USGS - Serviço Geológico dos Estados Unidos (acesso gratuito em: <https://espa.cr.usgs.gov/>). Elas foram mosaicadas no módulo OrthoEngine do software PCI Geomatics.

No software ENVI, através da técnica chamada de “álgebra de bandas” foram gerados os índices espectrais NDVI (NIR-Red/NIR+Red) e NDWI (MIR-NIR/MIR+NIR). Já no software TerrSet/IDRISI foram geradas as imagens transformadas (síntese das bandas de 1 a 7 do sensor OLI/LANDSAT-8) da Análise por Componentes Principais (PCA), IHS: Intensidade / Matiz / Saturação e TasseledCap: Brilho / Verdor / Umidade. Todos estes arquivos matriciais foram inseridos no projeto de classificação, uma vez que também objetivou-se avaliar a contribuição dos mesmos no processo de classificação (ou seja, descartou-se a adoção de atributos provenientes diretamente das bandas “puras” do sensor OLI). Também foi importado para o projeto de classificação, no eCognition Developer, o MDE do SRTM com 30 m de resolução espacial. A partir de todas essas imagens foram gerados os seguintes atributos espectrais: média, moda, desvio padrão, quartil, valores máximos e mínimos de pixel. Vale destacar que todos estes dados vetoriais foram recortados segundo o limite vetorial vigente da RMRJ no software ENVI antes da realização da classificação (Figura 2).




Figura 2. (A) NDVI, (B) NDWI, (C) TasseledCap: Brilho, (D) TasseledCap: Verdor, (E) TasseledCap: Umidade, (F): IHS e (G) PCA – R: 1ª componente, G: 2ª componente e B: 3ª componente e H: MDE do SRTM (adotado apenas nas regras de “Ajustes”).

O software eCognition Developer apresenta diferentes algoritmos de segmentação, porém aquele que se enquadrou na proposta deste trabalho foi o Chessboard Segmentation. Ele, por sua vez, divide a imagem em objetos quadrados, como se fosse uma grade (DEFINIENS, 2007). No Chessboard, um dos parâmetros solicitado ao usuário do sistema é justamente o tamanho do objeto. Neste caso, informou-se o valor 1 (um) para que fossem gerados objetos que delimitassem cada pixel de forma individual, ou seja, objetos com 900 m² (isso devido à resolução espacial de 30 m das imagens OLI/LANDSAT-8).

A etapa posterior consistiu na interpretação visual do mosaico de imagens. A partir dela foram definidas cinco classes temáticas, a saber: Vegetação, Mangue, Impermeável (em geral refere-se aos objetos que compõem as áreas urbanas), Água e Outros (englobam às áreas de pastagem, áreas úmidas, solo exposto e rocha exposta). Em seguida procedeu-se à coleta de amostras (Figura 3). Vale destacar que nesta etapa é necessário ter considerável cuidado para selecionar as amostras mais representativas devido à diversidade de alvos que compõem a cobertura da terra, e também pela qualidade das classificações geradas, uma vez que, a precisão das amostras implica diretamente neste quesito. No ArcGIS, as amostras foram adquiridas através da vetorização de quadrados de 180 m x 180 m dentro de uma dada classe (buscou-se coletar pixels tidos como “puros” ou o mais próximo disso, como ocorre na coleta para a realização do Modelo Linear de Mistura Espectral). Posteriormente o arquivo shapefile (SHP) contendo as amostras foi importado para o eCognition Developer e incorporado à segmentação existente (proveniente do Chessboard) através da ferramenta Assign Class By Thematic Layer.




Figura 3. Exemplo de amostra coletada para a realização da classificação.

Vale destacar que foram coletadas amostras para cada uma das cinco classes. Isto, porque o processo de Mineração de Dados adotado neste trabalho apresenta um caráter supervisionado. No eCognition Developer através da ferramenta Classifier é que se tem acesso aos diferentes algoritmos de Mineração de Dados Geográficos. São eles: Decision Tree (CART), BAYES, SVM, KNN e Random Trees. Entre eles, adotou-se o CART, uma vez que, o mesmo é o único que possibilita a consulta ao modelo simbólico gerado, ou seja, a árvore de decisão. Sobre ela, Han & Kamber (2001) afirmam ser um fluxograma onde cada nó interno (não-folha) denota um teste em um atributo, cada ramo representa um resultado do teste, e cada nó-folha ou nó-terminal possui um rótulo da classe. Assim, a primeira etapa requerida no sistema foi o Treino, onde justamente são indicadas as amostras e, por sua vez, também ocorre a elaboração do modelo de classificação a partir da descoberta de padrões nos dados. A etapa posterior consistiu na Aplicação deste mesmo modelo, ou seja, nela é que ocorre a classificação propriamente dita. A última etapa foi a Consulta, onde é apresentada a árvore de decisão (os demais algoritmos são considerados do tipo “Caixa-Preta”, pois não apresentam o modelo adotado para classificar).

Após a classificação foram geradas algumas regras (“Ajustes”) tendo como base o conhecimento do intérprete com o intuito de melhorar a classificação e outras mais regras (“Refino”) que adequaram à classificação à escala cartográfica de 1:100.000. A última etapa consistiu na avaliação da precisão da classificação através do índice Kappa (LANDIS & KOCH, 1977). Para tal, foram gerados 600 pontos de forma aleatória e estratificada através da ferramenta Create Random Points disponível no ArcMap/ArcGIS.

RESULTADOS

Como já dito, o processo de Mineração de Dados Geográfico aplicado neste trabalho foi do tipo supervisionado, assim, isto possibilitou que a geração do modelo de classificação das imagens fosse realizado mais de uma vez, três ao todo, devido terem sido constatadas imprecisões iniciais nas duas primeiras classificações, acarretando na coleta de novas amostras ou supressão algumas antigas justamente visando a melhoria do resultado. Acerca da integração entre GEOBIA e Mineração de Dados Geográficos, Carvalho (2018) propôs uma adaptação ao modelo de Antunes (2003) apresentado na Figura 4.

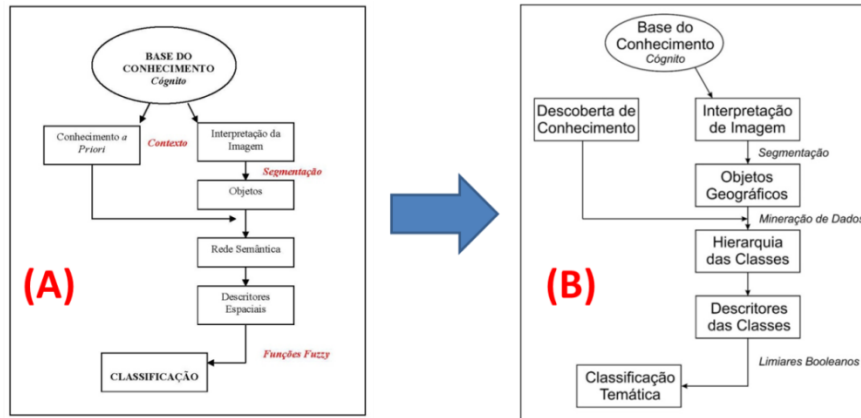


Figura 4. (A) Modelo conceitual da classificação por GEOBIA proposto por Antunes (2003) e (B) adaptação deste modelo para a integração entre GEOBIA e Mineração de Dados Geográficos.

Assim como no modelo de Antunes (2003) parte-se da premissa de que o intérprete possui algum conhecimento sobre os objetos a serem classificados, mas emprega-o apenas na interpretação visual da imagem. Da mesma forma que na Modelagem de Conhecimento a etapa seguinte consistiu na delimitação dos objetos geográficos, ou seja, na segmentação. O algoritmo de Mineração de Dados Geográficos necessita ser treinado pelo usuário a partir da seleção de objetos previamente rotulados (amostras). O minerador de dados selecionará a hierarquia das classes, os atributos e os respectivos limiares (booleanos). Já, a etapa final consistirá na classificação temática. Na Figura 5 é apresentada a árvore de decisão elaborada na Mineração de Dados pelo Decision Tree (CART) presente no Classifier. Ao observá-la percebemos que no conjunto de treze atributos utilizados, o único índice espectral escolhido foi o NDVI. Já, entre as imagens transformadas, sete atributos selecionados foram da Transformação TasseledCap. O Matiz proveniente da Transformação IHS foi requisitado quatro vezes. A 2ª PCA foi requisitada apenas uma vez.

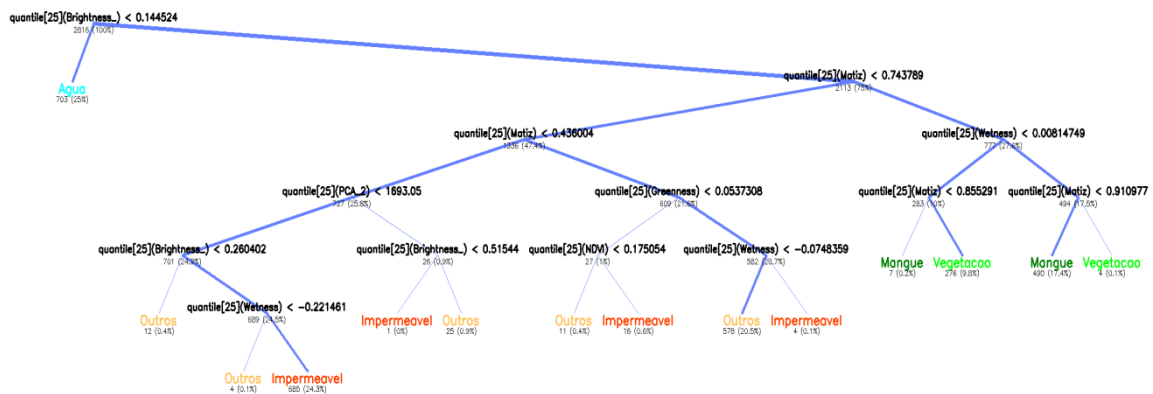


Figura 5. Árvore de decisão gerada através da Mineração de Dados e adotada na classificação da imagem OLI/LANDSAT-8.

Conforme apresentado na Figura 6 podemos perceber que a classificação apresentou algumas imprecisões, o mesmo tipo de erros que rotineiramente constatamos em classificações baseadas em agrupamentos de pixels (segmentos) ou em pixels.

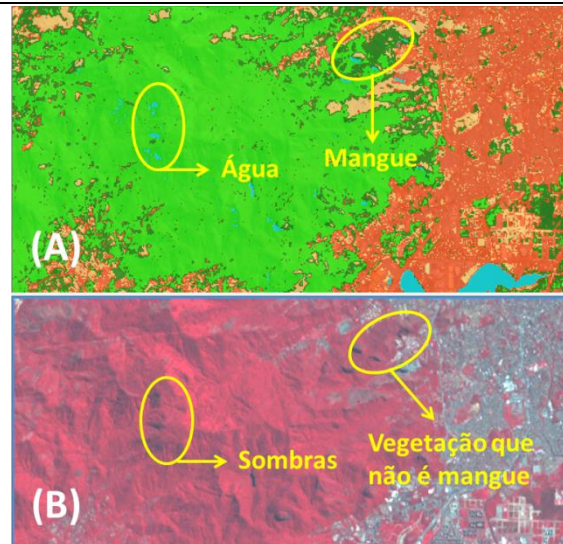


Figura 6. A: imperfeições apresentadas na classificação antes da utilização das regras de “Ajustes”, e em B: os corretos objetos na cobertura da terra.

Contudo, tais inconsistências puderam ser superadas em função da geração de conjuntos de regras, chamado de “Ajustes”, que tiveram como base o conhecimento prévio do intérprete de forma heurística (Figura 7). Esta premissa de integrar a Descoberta de Conhecimento (Mineração de Dados Geográficos) ao conhecimento prévio do intérprete garante um caráter híbrido à metodologia adotada no estudo em questão.

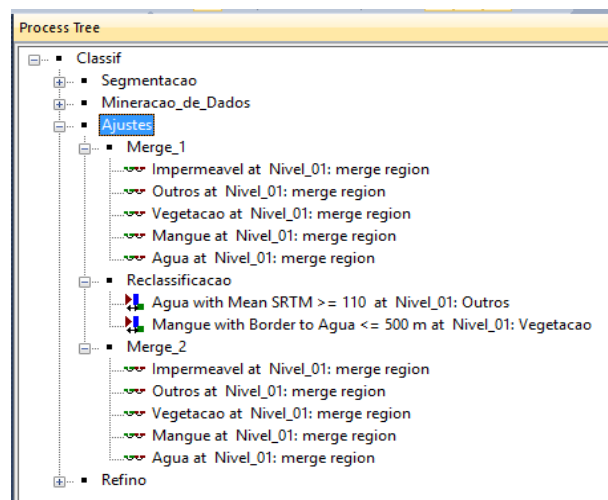


Figura 7. Conjunto de regras que compõem “Ajustes” presente na Árvore de Processo.

As primeiras regras propostas fizeram uso da função de fundir (merge). A partir dela os segmentos, ainda em forma de pixel, já classificados adquiriram a forma dos elementos que compõem a cobertura da terra (Figura 8).




Figura 8. Demonstração da aplicação da ferramenta Merge, onde fica notório que os pixels adquiriram o formato dos objetos presentes na cobertura da terra (em A os objetos estão com a classificação fechada e em B estão com a classificação apresentando apenas o limite).

O segundo conjunto de regras que integra o conjunto “Ajustes” abordou à reclassificação dos objetos. Nele, adotou-se os valores médios do MDE do SRTM maiores ou iguais a 110 para corrigir as áreas de sombras que foram erroneamente classificadas como água que estavam nos maciços. Outra regra adotada foi referente à questão da localização espacial dos mangues. Nela, adotou-se o atributo de Borda para Água menor ou igual a 500 metros (Figura 9). Por fim, novamente utilizou-se a ferramenta Merge para agregar os objetos reclassificados aos objetos rotulados corretamente na classificação inicial.




Figura 9. A: classificação anterior à aplicação das regras de “Ajustes”. B: classificação com as inconsistências já corrigidas pela aplicação das regras de “Ajustes”.

O mapeamento neste trabalho foi elaborado de forma a ser compatível com a escala cartográfica de 1:100.000. Desta forma, elegeu-se como menor objeto mapeável aquele que apresenta dimensão inferior a cinco hectares, assim como em Abreu (2010). Contudo, para garantir tal premissa, gerou-se um conjunto de regras no eCognition Developer denominado de “Refino”, tendo como base os mesmos algoritmos geométricos e relacionais (vizinhança) utilizados em Carvalho (2011). São eles, a saber: Área (em pixels), Borda relativa (Relative Border) e Encontrar Cercado pela Classe (Find Enclosed by Class), conforme demonstrado pela Figura 10.

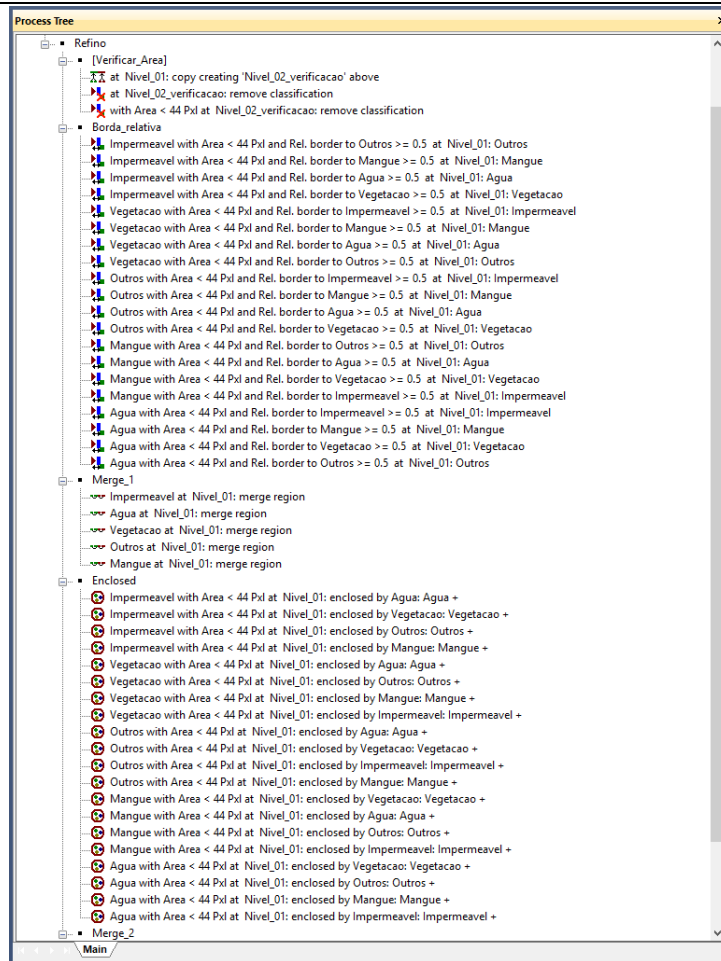


Figura 10. Conjunto de regras que compõem “Refino” presente na Árvore de Processo.

O resultado da aplicação do conjunto de regras de “Refino” é apresentado etapa por etapa na Figura 11.

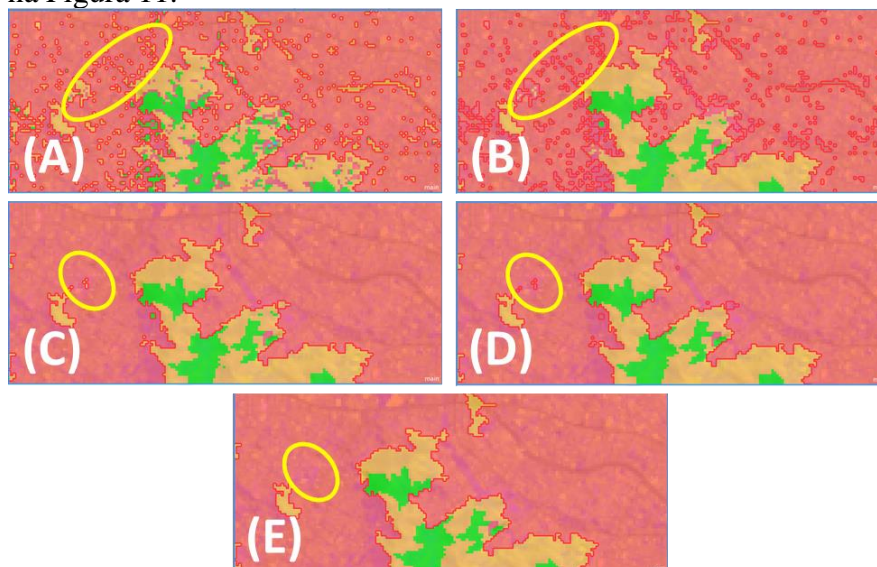


Figura 11. Aplicação das regras de Refino – (A): objetos menores que 5 hectares; (B): objetos menores que 5 hectares foram detectados e reclassificados pelas relações de vizinhança; (C): objetos remanescentes que não foram classificados; (D): objetos foram reclassificados pela questão da vizinhança e (E): objetos foram incorporados pela aplicação da ferramenta Merge.

Ao observarmos a Figura 12 notamos que os objetos presentes na cobertura da terra apresentaram satisfatória delimitação. Em relação à exatidão da classificação, através da comparação dos 600 pontos com a classificação e as imagens do software Google Earth (adotado como verdade de campo) calculou-se o Índice Kappa. Assim, através do mesmo obteve-se uma precisão de 0,871 (sem edições manuais), que por sua vez é considerado excelente na escala proposta por Landis & Koch (1977).




Figura 12. Demonstração da qualidade da classificação final - (A): região do Aeroporto Internacional do Galeão e (B): região do Parque Estadual do Mendanha.

Na Figura 13 é apresentado o mapa temático que representa o produto final do trabalho em questão. Em ambiente ArcMap/ArcGIS foi calculada a área para cada classe temática. Assim, chegou-se aos seguintes resultados: Mangue - 132.47 km², Água - 291.53 km², Impermeável - 1409 km², Outros - 2035.25 km² e Vegetação - 3308.30 km².

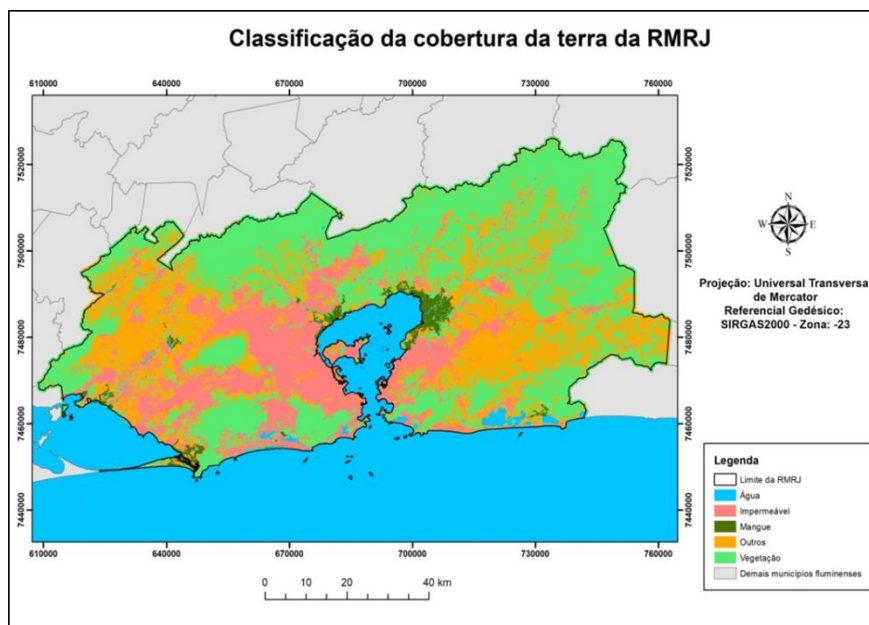


Figura 13. Mapa temático de cobertura da terra na RMRJ, produto final do trabalho.

CONCLUSÕES

Os resultados evidenciam um elevado potencial da abordagem fazendo uso de pixels individuais sendo tratados como objetos em imagens de média resolução espacial, tais como os dados OLI/LANDSAT-8 em software voltado para GEOBIA. A

Mineração de Dados Geográficos contribuiu efetivamente na classificação, além de apontar, através da árvore de decisão, quais atributos espectrais mais contribuíram neste mapeamento, neste caso as imagens provenientes da Transformação TasseledCap. Acredita-se que adotar somente a Modelagem de Conhecimento ao invés da Descoberta de Conhecimento (Mineração de Dados Geográficos) neste tipo de abordagem possa ser um desafio bastante árduo visto a considerável quantidade de pixels a serem classificados (7.992.169 objetos ao todo). Tanto a Mineração de Dados quanto o conhecimento prévio do intérprete (regras de “Ajustes”) possibilitaram alcançar a excelente precisão apresenta na classificação final. Vale destacar que as ferramentas presentes no software de classificação por GEOBIA, tais como “Merge”, “Find Enclosed By Class” e “Border To” possibilitaram a satisfatória delimitação das classes de cobertura da terra, além da adequação à escala de mapeamento pelas regras de “Refino” (objetos inferiores a 5 hectares foram aglutinados pelos outros objetos maiores).

AGRADECIMENTOS

Os autores expressam seus agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa de estudo (Doutorado) ao primeiro autor e também, à Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa à segunda autora (PIBIC-UFRJ).

REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A. F. B. Classificação de ambiente ciliar baseada em orientação a aplicadas ao mapeamento da cultura da cana-de-açúcar, 2010.

ARAÚJO, E. H. G. Análise multi-temporal de cenas do satélite QuickBird usando um novo paradigma de classificação de imagens e inferências espaciais. Estudo de caso: Belo Horizonte, MG. 2006. 175 p. (INPE-13956- TDI/1062). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2006. Disponível em: <<http://urlib.net/sid.inpe.br/MTCm13@80/2006/07.24.19.43>>. Acesso em: 23 jan. 2009.

ABREU, M. B. Análise Espaço temporal da Cobertura e Uso da Terra no Rio de Janeiro de 1994 até 2007. Dissertação (Mestrado em Geografia) - Universidade Federal do Rio de Janeiro (UFRJ), 2010.

CARVALHO, M. V. A. Classificação da cobertura e uso do solo com imagens Worldview-2 utilizando mineração de dados e análise baseada em objetos. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), 2011.

CARVALHO, M. V. A. Classificação digital híbrida aplicada ao monitoramento e análise das superfícies impermeáveis na Região Metropolitana do Rio de Janeiro (RJ). Tese (Doutorado em Geografia) – Universidade Federal Fluminense (UFF), 2018.

DEFINIENS. DEFINIENS professional 7: reference book. Munich: DEFINIENS (The Deguchi C, Sugio S. Estimations for the percentage of impervious area by the use of

satellite remote sensing imagery. *Journal of Soil and Water Conservation*. 1994; 29(1-2):135-144.

HAN, J.; KAMBER, M. *Data Mining: Concepts and Techniques*, 2nd ed. The Morgan Kaufmann Series in Data Management Systems, Jim Gray, Series Editor Morgan Kaufmann Publishers, 2006.

IBGE: INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Censo demográfico. Rio de Janeiro, 2010.

INPE: INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Sistema de ajuda on-line do SPRING. São José dos Campos, 2012.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. *Biometrics*, v.33, n.1, p.159-174, 1977.

SOARES FILHO, B. S. *Interpretação de Imagens da Terra. Curso de Especialização em Geoprocessamento*. UFMG, 2000. Disponível em <<http://www.csr.ufmg.br/geoprocessamento/publicacoes/intimagem.pdf>> Acesso em: 15 jan. 2013.

ENDEREÇO PARA CORRESPONDÊNCIA COM OS AUTORES

1 – UFF: Universidade Federal Fluminense - Departamento de Geografia / IGEO - POSGEO: Programa de Pós-Graduação em Geografia: Av. General Milton Tavares de Souza, s/nº - Campus da Praia Vermelha - Gragoatá - Niterói, RJ - Brasil - CEP: 24.210-346 (marcus.br@gmail.com).

2 – UFRJ: Universidade Federal do Rio de Janeiro - Departamento de Geografia / CCMN / IGEO - Laboratório ESPAÇO: Sensoriamento Remoto e Estudos Ambientais: Av. Athos da Silveira Ramos, 274 - Ilha do Fundão - Rio de Janeiro, RJ – Brasil - CEP: 21.949-900 (gabriella.geoufrj@gmail.com; carlamad@gmail.com).