

ANÁLISE DA EXPANSÃO URBANA NA CIDADE DO RIO DE JANEIRO - ÁREA DE PLANEJAMENTO 4: ENSAIOS PRELIMINARES PARA A DETECÇÃO DE MUDANÇAS HÍBRIDA

Marcus Vinícius Alves de Carvalho^{1,2}

Gabriella Ferreira da Silva²

Carla B. Madureira Cruz²

Raúl Sánchez Vicens¹

1 - UFF: Universidade Federal Fluminense - LAGEF: Laboratório de Geografia Física - (marcus.br@gmail.com, rsvicens@gmail.com)

2 - UFRJ: Universidade Federal do Rio de Janeiro - ESPAÇO: Laboratório de Sensoriamento Remoto e Estudos Ambientais - (gabriella.geoufrj@gmail.com, carlamad@gmail.com)

ABSTRACT

Geography is one of several fields of knowledge that traditionally uses remote sensing data to understanding the environment. Through these data it can extract important information for production of thematic maps that contribute to decision-making, as is the case of mappings performed in urban areas (in Brazil, about 80% of the population lives in urban areas). The objective this paper is to evaluate the different change detection techniques integrated into GEOBIA (hybrid change detection) and Data Mining in order to analyze the urban sprawl in the AP4 in the Rio de Janeiro City. The best results were obtained through the products of the PCA (Kappa Index: 0.79) and Image Difference (Kappa Index: 0.75).

Keywords: Urban sprawl, Hybrid change detection, Remote sensing, GEOBIA, Data mining.

INTRODUÇÃO

O avanço da urbanização em nosso país tem provocado sérios impactos no modo de vida da população. O contínuo aumento da impermeabilização do solo, da densidade demográfica e de construções em locais impróprios, dentre outros, são sempre acompanhados de graves problemas sociais e econômicos, além de impactos negativos na infraestrutura urbana e no meio ambiente (ARAÚJO, 2006). Assim, cada vez mais é necessária a constante aquisição de informações atualizadas sobre os ambientes urbanos. Desta forma, devido ao seu caráter sinótico, multitemporal, multiespectral e de menor custo (em comparação aos levantamentos aerofotogramétricos), os produtos de sensoriamento remoto orbital têm se mostrado de relevante utilidade e eficiência neste tipo de análise, alcançando resultados bastante satisfatórios.

Por meio da análise de dados de Sensoriamento Remoto de épocas distintas é possível realizar a detecção de mudanças na cobertura e uso do solo. Esta análise permite inferir sobre a dinâmica das transformações em vários outros aspectos, como intensidade, tipo de mudança e as taxas de mudança detectadas em uma região durante um determinado

período. Essas mudanças ocorridas na cobertura do solo ao longo do tempo, dependendo do tipo, origem e intensidade podem gerar impactos socioeconômicos consideráveis.

Assim, o presente trabalho tem por objetivo avaliar quatro diferentes técnicas de detecção de mudanças (Image Difference, PCA: Principal Components Analysis, MNF: Minimum Noise Fraction e ICA: Independent Component Analysis) em imagens TM/Landsat 5 e OLI/Landsat 8 a fim de analisar o fenômeno da expansão urbana na Área de Planejamento 4 (AP4) do município do Rio de Janeiro (intervalo de tempo de 13 anos) adotando ainda a detecção de mudanças híbrida (JYANIA et al., 2008) e mineração de dados.

METODOLOGIA

A área de estudo corresponde à Área de Planejamento 4 (AP4), no município do Rio de Janeiro. Ela compreende as regiões administrativas da Barra da Tijuca, Cidade de Deus e Jacarepaguá. A AP4 teve um crescimento de 72,78% entre os censos de 1991 e 2010, com uma população residente estimada em 909.368 habitantes (IBGE, 2010). Merece destaque o fato de que nesta região foram e ainda estão sendo construídos os corredores expressos de transporte (BRT Transcarioca, Transoeste e Transolímpica) e a maior parte do aparato para receber as Olimpíadas de 2016 (estádios, hotéis, entre outros). Assim, tais informações corroboram para a escolha da mesma para o estudo da expansão urbana.

As etapas metodológicas aplicadas neste trabalho são representadas na Figura 1.

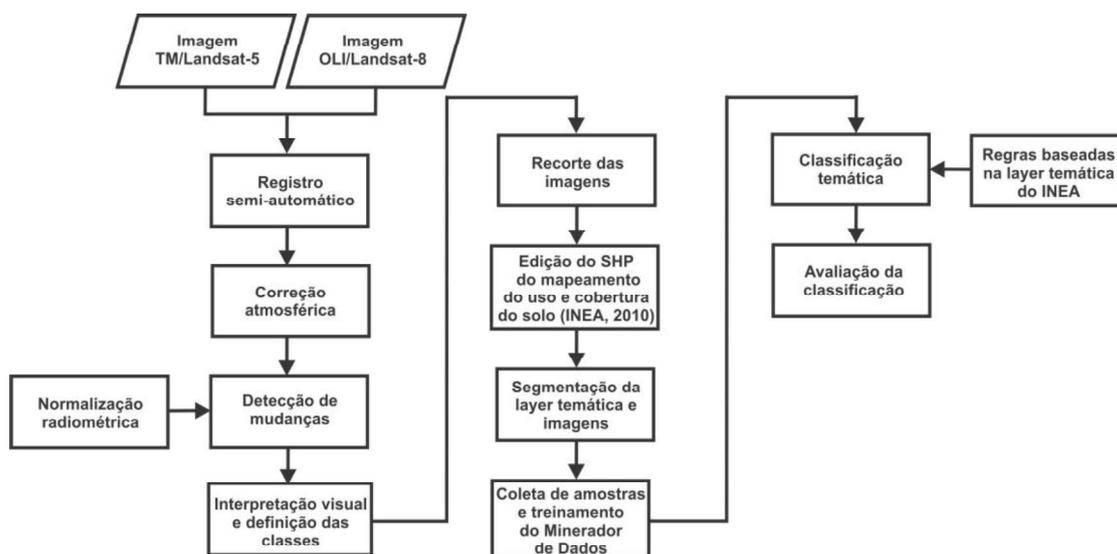


Figura 1. Fluxograma representando as etapas desenvolvidas durante a pesquisa.

A aquisição de todas as imagens orbitais foi realizada através do Centro de Dados de Sensoriamento Remoto (CDSR) da Divisão de Geração de Imagens (DGI) do INPE

(<http://www.dgi.inpe.br/CDSR/>). Foram adquiridas 2 imagens da série Landsat. São elas, a saber:

TABELA 1: ALGUMAS CARACTERÍSTICAS DAS IMAGENS ADOTADAS NESTE ESTUDO

Imagem	Sensor/Satélite	Aquisição	Res. radiométrica	Res. espacial
LANDSAT_5_TM_20000814_217_076_L2	TM/Landsat-5	14/08/2000	8 bits	30 m
LC82170762013214LGN00	OLI/Landsat-8	02/08/2013	12 bits	30 m

Neste estudo adotou-se especificamente estas imagens da série Landsat devido as mesmas serem gratuitas e ainda pela quase total ausência de nuvens. Isto é um fator considerável quando se trabalha com imagens ópticas devido à cobertura de nuvens possivelmente ocultar os objetos de interesse.

A etapa posterior consistiu na correção atmosférica das imagens. Para tal, optou-se pelo algoritmo ATCOR (Atmospheric and Topographic Correction for Satellite Imagery), pois ele baseia-se em um modelo de transferência radiativa do tipo MODTRAN (Moderate Resolution Atmospheric Transmission). De acordo com Ponzoni e Shimabukuro (2007), os procedimentos aplicados às imagens com o intuito de reduzir o efeito da atmosfera acarretam alterações nos atributos espectrais e radiométricos de diferentes objetos que estão na superfície terrestre, o que por sua vez, pode interferir em processos de classificação.

A etapa seguinte consistiu na correção geométrica das imagens. Adotou-se para esta tarefa o software gratuito Regeemy 0.2.43 (Image Registration and Mosaicking); que consiste em um sistema semi-automático de registro e mosaico de imagens de sensoriamento remoto desenvolvido pela Divisão de Processamento de Imagens do INPE e UCLA VisonLab do Departamento de Engenharia Elétrica e Computação da Universidade da Califórnia. Segundo Fedorov (2002), este software demonstra potencial para registro de imagens multitemporais e multisensores e é projetado para aceitar diferentes tipos de dados e agregar conhecimentos do usuário para acelerar o processo e evitar erros, pois o usuário pode ainda parar ou continuar modificando os parâmetros do processo. O Regeemy encontra-se disponível para download gratuito em: <http://wiki.dpi.inpe.br/doku.php?id=wiki:regeemy>. Como as imagens OLI/Landsat-8 já encontram-se ortorretificadas (*Level 1T*), tanto as imagens disponíveis no Catálogo da DGI/INPE quanto nos portais do Serviço Geológico Americano (USGS), ela serviu de base para a correção geométrica (sabe-se que as imagens TM/Landsat-5 também

encontram-se ortorretificadas no site do USGS, no entanto, optou-se por avaliar o Regeemy).

O ENVI através da ferramenta “Image Change Workflow” no módulo “Change Detection”, apresenta dois modos para realizar a detecção de mudanças. São eles, a saber:

- Image Difference: executa a diferença entre imagens (bitemporal), com ou sem opção de limiar de mudança (opcional ao usuário), e sem a realização de transformação da imagem.
- Image Transform: executa uma transformação, também bitemporal (métodos disponíveis: PCA, MNF, e ICA), e cria uma imagem de diferença, sem as opções de mudança de limiar.

Vale mencionar que a ferramenta “Image Change Workflow” permite que o usuário refine a precisão do posicionamento entre as imagens para que não sejam gerados “artefatos” na detecção de mudanças.

A importância de tal ferramenta se deve ao fato de que sensores remotos são muito utilizados no monitoramento de mudanças na superfície terrestre, fornecendo informações consistentes e medições repetidas em escala apropriada para muitos processos que incluem agentes naturais, antrópicos e mudanças climáticas (KENNEDY et al., 2007).

Como o objetivo deste trabalho é avaliar métodos de detecção de mudanças para a análise da expansão urbana na AP4, e pelos métodos selecionados realizarem tal tarefa banda por banda ou índice por índice, optou-se por aplicar os experimentos de detecção de mudanças apenas na banda 3 do TM/Landsat-5 e banda 4 do OLI/Landsat-8, devido DGI/INPE (2015) ressaltar que, a banda do vermelho (0,63 - 0,69 μm) é a mais utilizada para delimitar a mancha urbana, incluindo identificação de novos loteamentos.

A etapa seguinte consistiu na segmentação das imagens provenientes dos métodos de detecção de mudança já citados anteriormente. Para tal foi utilizado o Multiresolution Segmentation. Segundo Trimble (2014), este algoritmo minimiza a heterogeneidade média dos objetos da imagem para uma determinada resolução de objetos. Ele pode ser executado em um nível de objetos existente (imagem segmentada) ou diretamente no pixel para criar objetos em um novo nível.

A etapa que segue consistiu na interpretação visual e seleção de amostras para treinar o algoritmo de Mineração de Dados. Neste trabalho foi utilizado o CART (Classification And Regression Tree), implementado no software eCognition Developer, que faz uso da técnica de indução por árvore de decisão (conhecimento simbólico). Para a obtenção do modelo de classificação pelo CART é exigida uma etapa de treinamento (Train) onde é feita a coleta das amostras dos objetos da imagem, etapa de classificação onde ocorre

a mineração de dados (descoberta de padrões nos dados) propriamente dita e a aplicação do modelo gerado para gerar a classificação temática (Apply). A apresentação e exportação da árvore de decisão que foi aplicada no passo anterior consiste na última parte (Query).

As avaliações das classificações foram feitas através da exportação dos objetos do formato SHP para KMZ e comparação direta com as imagens de alta resolução (verdade terrestre) do acervo histórico do Google Earth (SUTTON et al., 2006) e as ortofotos da Prefeitura do Rio de Janeiro que estão disponíveis para download em PDF na Internet (http://portalgeo.rio.rj.gov.br/ortofotos/ortof_new.asp), cálculo de área de cada classe e cálculo do índice Kappa (COLGATON & GREEN, 1999).

RESULTADOS

Através do software Regeemy 0.2.43 foram gerados 687 tie points pelo método de transformação Affine. O modelo foi resolvido com a Raiz do Erro Médio Quadrático (RMSE) equivalente a 0.327 pixel (o próprio Regeemy realiza esta avaliação estatística), o corresponde a menos da metade de 1 pixel. Resultado consideravelmente satisfatório. Os métodos de detecção de mudanças aplicados foram divididos em quatro experimentos. São eles: Experimento 1 - Imagem Diferença, Experimento 2 - PCA, Experimento 3 - MNF e Experimento 4 - ICA (Figura 2).

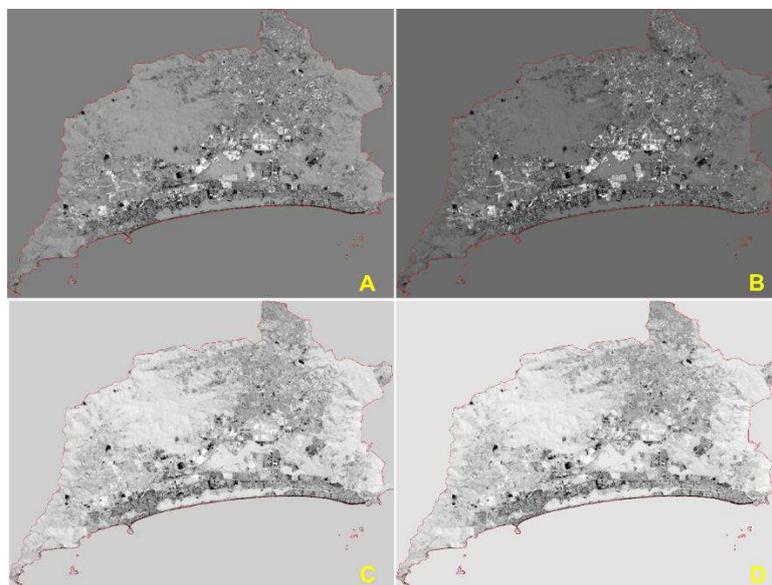


Figura 2. Imagens provenientes dos quatro experimentos (todas com contraste linear de 2%). Os objetos em tons mais claros são os objetos onde ocorreram as mudanças. Nota-se que visualmente os experimentos que destacaram consideravelmente as mudanças foram Diferença de Imagem (A) e PCA (B). Já em MNF (C) e ICA (D) as mudanças apareceram bem menos destacadas.

Após a geração das imagens com a detecção de mudanças, todas elas foram recortadas no ENVI a partir do limite oficial da AP4 (formato SHP) disponível para download no site do Instituto Pereira Passos (IPP) da Prefeitura da Cidade do Rio de Janeiro.

O primeiro nível hierárquico gerado no software eCognition corresponde ao layer temático (formato SHP) do mapeamento do uso e cobertura do solo do Estado do Rio de Janeiro (INEA, 2010), segmentado por meio do algoritmo Chessboard Segmentation (Tamanho de objeto: 100.000). Como o mapeamento é datado de 2010, foram realizadas algumas poucas edições com o intuito de atualizá-lo e todas as demais classes diferentes de “urbano” foram fundidas na classe “não-urbano”. Já, o segundo nível hierárquico consistiu nos objetos de “mudança” e “não-mudança” por meio das imagens resultantes dos 4 experimentos. Os parâmetros adotados para a segmentação foram os seguintes: Escala: 5 / Forma: 0,5 / Compacidade: 0,5.

Elaborou-se uma regra onde os sub-objetos “mudança” que não possuem o super-objeto “urbano” deveriam ser classificados como “outros”. Assim, objetos na linha de costa (alta dinâmica natural de mudanças) e em regiões florestais, entre outros não foram considerados como “mudança”. E os objetos de mudança que possuem o super-objeto “urbano” passaram a ser considerados “expansão”.

Para a classificação das imagens de todos os quatro experimentos foi adotado o mesmo conjunto de amostras (88 objetos correspondentes às mudanças e 90 objetos correspondentes à não-mudança) e de atributos espectrais (média, moda, quartil, desvio padrão, mínimo e máximo valor de pixel).

+ Experimento 1 - Diferença de Imagem

Segundo Exelis/ENVI (2015), o módulo Image Change aplica a seguinte equação para gerar a diferença de imagem:

$$(Momento\ 2 - Momento\ 1) / (Momento\ 2 + Momento\ 1)$$

Sabe-se que a imagem TM/Landsat-5 e a imagem OLI/Landsat-8 apresentam resolução radiométrica distinta (8 bits e 12 bits, respectivamente), no entanto, isto não representou empecilho para o módulo de detecção de mudanças implementado no ENVI.

Nesta opção existe a possibilidade de realizar ou não a normalização radiométrica. Ponzoni e Santos (2008), destacam que a normalização radiométrica torna-se obrigatória quando ocorre o emprego de dados provenientes de diferentes sensores, sejam estes defasados ou não no tempo. Estudos desenvolvidos no Lab. ESPAÇO da UFRJ demonstram que dados provenientes do mesmo sensor adquiridos em diferentes passagens também necessitam da normalização radiométrica. Assim, realizou-se um teste simples, a imagem diferença foi gerada com e sem a normalização. A avaliação

foi feita de forma visual apenas. Através da Figura 3 podemos perceber que a imagem sem normalização não destacou bem as mudanças. Contudo, o Experimento 1 não foi realizado na imagem sem a normalização.

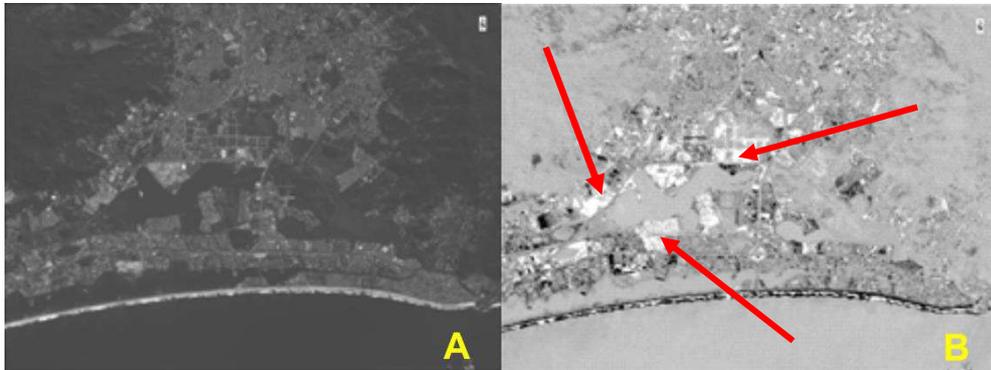


Figura 3. Imagem diferença gerada sem a normalização da imagem (A) e gerada com a normalização (B). Na imagem normalizada (B) percebe-se que as mudanças estão mais destacadas (objetos mais claros) que na imagem sem normalização (A). Vale destacar que ambas estão sendo apresentadas com contraste linear de 2%.

Através deste experimento obteve-se uma área de 15,19 km² para a classe “expansão”, 277,51 km² para a classe “não-mudança” e 1,30 km² para a classe “outros”. O índice Kappa alcançado foi de 0,75 (Figura 4).

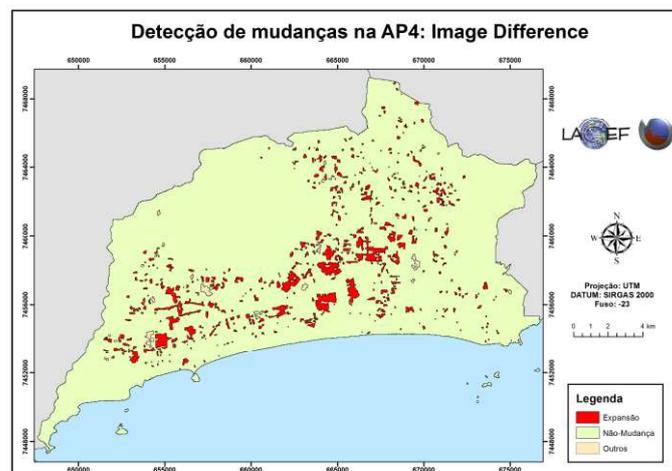


Figura 4. Mapa temático resultante da aplicação da técnica Image Difference com a classificação por GEOBIA e mineração de dados.

+ Experimento 2 - PCA: Principal Components Analysis

Segundo Exelis/ENVI (2015), este método produz bandas não-correlacionadas (as bandas de dados multiespectrais podem estar altamente correlacionados) para separar componentes de ruído, e para reduzir a dimensionalidade dos conjuntos de dados (Figura 5).

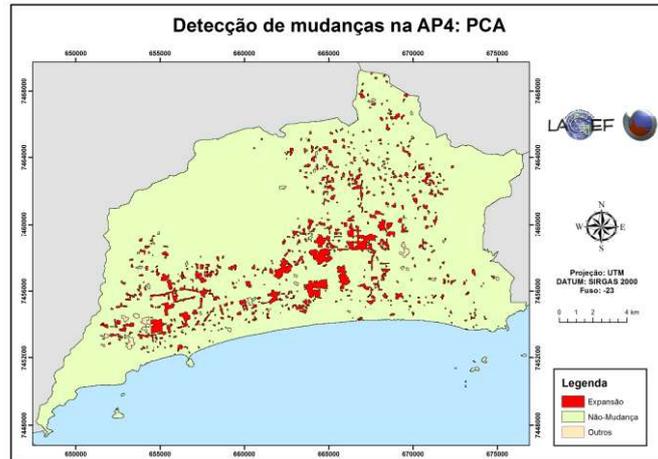


Figura 5. Mapa temático resultante da aplicação da técnica PCA com a classificação por GEOBIA e mineração de dados.

Através deste experimento obteve-se uma área de 18,44 km² para a classe “expansão”, 273,75 km² para a classe “não-mudança” e 1,82 km² para a classe “outros”. O índice Kappa alcançado foi de 0,79. Constatou-se que neste experimento mais objetos de mudança referentes à expansão urbana foram detectados na imagem que foi classificada. Acredita-se que isso se deva à descorrelação das bandas inerente ao processo da PCA.

+ Experimento 3 - MNF: Minimum Noise Fraction

Segundo Exelis/ENVI (2015), o MNF determina a dimensionalidade inerente de dados para isolar o ruído e reduzir os requisitos computacionais para o processamento posterior (Figura 6).

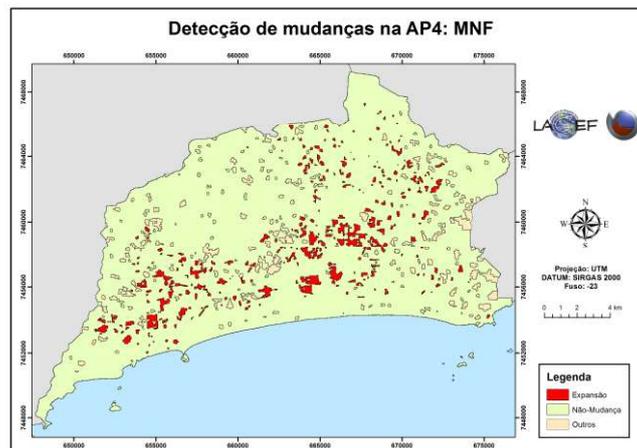


Figura 6. Mapa temático resultante da aplicação da técnica MNF com a classificação por GEOBIA e mineração de dados.

Através deste experimento obteve-se uma área de 12,65 km² para a classe “expansão”, 266,08 km² para a classe “não-mudança” e 15,28 km² para a classe “outros”. O índice Kappa alcançado foi de 0,56.

+ Experimento 4 - ICA: Independent Component Analysis

Exelis/ENVI (2015) destaca que esta técnica funciona bem com dados hiperespectrais em comparação com os métodos PCA e MNF. Um ponto negativo, é que ela requer mais recursos computacionais que os outros dois métodos (Figura 7).

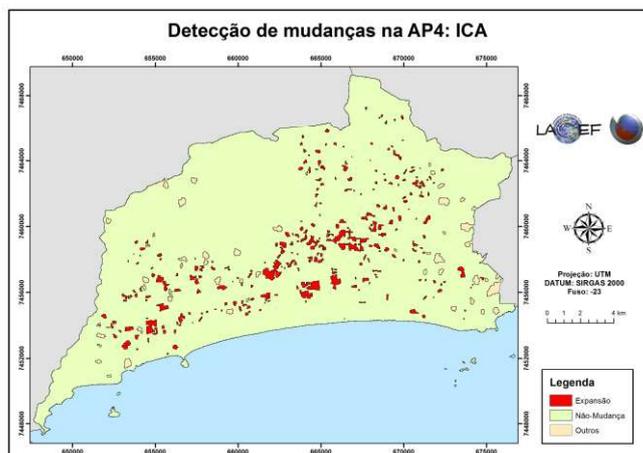


Figura 7. Mapa temático resultante da aplicação da técnica ICA com a classificação por GEOBIA e mineração de dados.

Como resultado do ICA obteve-se uma área de 9,55 km² para a classe “expansão”, 280,07 km² para a classe “não-mudança” e 4,39 km² para a classe “outros”. O índice Kappa alcançado foi de 0,31. O ICA foi aplicado com sua configuração padrão (Sampling Percentage: 10.00 / Maximum Iterations: 100 / Maximum Stabilization Iterations: 100 e Contrast Function: LogCosh).

CONCLUSÕES

Os resultados preliminares evidenciam um elevado potencial de todas estas técnicas para a análise multitemporal de dados de Sensoriamento Remoto. Ao levar-se em consideração o índice Kappa (que teve como verdade terrestre as imagens históricas disponíveis no software Google Earth e as ortofotos da Prefeitura do Rio de Janeiro), as técnicas PCA e Image Difference apresentaram resultados bem interessantes.

Este trabalho não busca esgotar o assunto, contudo, faz-se necessário realizar mais testes com as outras bandas dos sensores TM e OLI e ainda, avaliar a normalização radiométrica realizada pelo módulo de detecção de mudanças do ENVI. Vale também realizar mais testes envolvendo as técnicas MNF e ICA com outros dados e parâmetros, visto que a detecção de mudanças é um campo bastante promissor com a possibilidade de integração com GEOBIA e técnicas de mineração de dados, redes neurais, entre outras.

REFERÊNCIAS BIBLIOGRÁFICAS

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.

COLGATON, R.G; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. New York: Lewis Publishers, 1999. 123 p.

DGI: DIVISÃO DE GERAÇÃO DE IMAGENS/INPE: INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Os satélites LANDSAT 5 e 7. Disponível em: <http://www.dgi.inpe.br/Suporte/files/Cameras-LANDSAT57_PT.php>. Acesso em: 29 ago. 2015.

EXELIS Visual Information Solutions/ENVI. ENVI Help. USA. 2015.

FEDOROV, D. Sistema semi-automático de registro e mosaico de imagens. 2002. 155 p. (INPE-9582-TDI/838). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2002. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2003/07.18.10.21>>. Acesso em: 04 set. 2015.

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

INEA: INSTITUTO ESTADUAL DO AMBIENTE. O Estado do Ambiente: Indicadores Ambientais do Estado do Rio de Janeiro. Rio de Janeiro. 2010. Disponível em: <<http://www.inea.rj.gov.br/Portal/MegaDropDown/EstudosePublicacoes/Publicaes/EstadoAmbiente/index.htm&lang=>>>. Acesso em: 02 ago. 2015.

JIANYA, G.; HAIGANG, S.; GUORUI, M.; QIMING, Z. A Review of Multi-Temporal Remote Sensing Data Change Detection Algorithms. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B7. Beijing, China. 2008.

KENNEDY, R. E.; COHEN, W. B.; SCHROEDER, T. A. Trajectory-based change detection for automated characterization of forest disturbance dynamics. Remote Sensing of Environment, v. 110, n. 3, pp. 370-386, 2007.

PONZONI, F. J.; SANTOS, S. B. Conversão de números digitais de imagens orbitais em valores de FRB de superfície. Bol. Ciênc. Geod, Curitiba, v. 14, no 4, p.541-556, out-dez, 2008.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. São José dos Campos: A. Silva Vieira Ed., 2007. 127 p.

SUTTON, P. C.; TAYLOR, M. J.; ANDERSON, S. ELVIDGE, C. D. Sociodemographic characterization of urban areas using nighttime imagery, Google Earth, Landsat and "social" ground truthing. In.: WENG, Q; QUATTROCHI, D. A. Urban remote sensing. 1. ed. Boca Raton: CRC Press, 2006.

TRIMBLE. eCognition Developer 9.0: Reference Book. Munich. 2014.