

Análise da integração entre Sensoriamento Remoto e SIG na classificação da cobertura da terra em Duque de Caxias/RJ

RESUMO

Fernando de Souza Antunes

fernando.antunes@ufrj.br

orcid.org/0000-0002-8903-3145

Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, Rio de Janeiro, Brasil.

Luciana Viana Neves

ciana.vn@gmail.com

orcid.org/0000-0003-2446-7548

Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, Rio de Janeiro, Brasil.

Kairo da Silva Santos

kairo.geo@gmail.com

orcid.org/0000-0001-5606-2727

Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, Rio de Janeiro, Brasil.

Alan José Salomão Graça

alanjsg@gmail.com

orcid.org/0000-0002-0580-6746

Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, Rio de Janeiro, Brasil.

A análise de imagens de Sensoriamento Remoto baseada em objetos geográficos, também conhecida como GEOBIA, constitui uma das áreas mais promissoras de pesquisas em Sensoriamento Remoto e Processamento Digital de Imagens. Nesta perspectiva, o presente trabalho tem como proposta explorar algumas abordagens práticas sobre o processo de classificação de imagens baseada em objetos integrada com SIG, com o intuito de gerar um mapeamento de cobertura da terra do município de Duque de Caxias/RJ, utilizando uma cena do sensor OLI do satélite Landsat8. Na imagem utilizada, foi feita a correção atmosférica utilizando o módulo ATCOR2 e, posteriormente a fusão das bandas RGB com a banda pancromática. A segmentação foi feita com segmentador *Multiresolution Segmentation* a classificação utilizando a chave: vegetação densa; vegetação rasteira; urbano; solo exposto; e água. Após a validação do mapeamento gerado pela modelagem do conhecimento, foram obtidos resultados para o índice Kappa (90,83%), exatidão global (93%) e precisão de classe, onde o menor resultado foi de solo exposto, com 83,33%. Entende-se que a imagem OLI/Landsat8 é um bom produto para classificação de imagens a nível municipal. Além disso, entende-se que a integração SIG/Sensoriamento Remoto é uma alternativa para dificuldades encontradas na modelagem do conhecimento.


PALAVRAS-CHAVE: Integração GEOBIA e SIG. Mapeamento de Cobertura da Terra. MDE. SRTM.

INTRODUÇÃO

Os processos de tratamento e classificação de imagens obtidas por sensores transportados por plataformas orbitais passaram por diversas transformações nas últimas décadas, acompanhando a evolução da qualidade e confiabilidade do imageamento obtido por satélite. Desde o início do ano 2000 com a comercialização das imagens do sensor Ikonos, seguido no final do ano de 2001 pelo lançamento bem-sucedido, e início das operações, do satélite QuickBird-2, novas possibilidades foram colocadas a prova para o uso das imagens orbitais (BLASCHKE *et al.*, 2007).

Os sensores de altíssima resolução espacial e as formas de interpretação de seus dados constituem uma das áreas mais atuais de pesquisas em sensoriamento remoto e processamento digital de imagens, justificando a emergência de novos paradigmas de análise que vão além da classificação espectral dos alvos imageados. Em outras palavras, Ehlers (2007) discute que os sensores de alta resolução espacial proporcionaram a observação das feições terrestres de forma detalhada, a construção de modelos digitais de elevação com o uso de pares estéreos do mesmo sensor (uma vez que possuem visada off-nadir), monitoramento de catástrofes naturais e o monitoramento de áreas com curtos períodos sem a cobertura de nuvens devido à grande resolução temporal. Contudo, além das vantagens, o emprego desses sensores carece de novos conhecimentos para classificar os alvos, individualizar as feições, além de demandar processos mais rigorosos de tratamento das imagens na fase de pré-processamento (correções atmosférica e geométrica). Isso produz uma cadeia causal que ajuda a ilustrar como ocorre a evolução do conhecimento na área de sensoriamento remoto (Figura 1).

Figura 1 – Cadeia causal idealizada no desenvolvimento do Sensoriamento Remoto



Fonte: Adaptado de Ehlers (2007).

Em meio a esse quadro de busca por novos procedimentos de interpretação para imagens de alta e altíssima resolução espacial (EHLERS, 2007), emergem técnicas como a Análise de Imagens Baseada em a Objetos Geográficos ou GEOBIA. Diferentemente dos métodos de classificação de imagens tradicionais, a GEOBIA (ou OBIA) possibilita o uso de diferentes atributos dos objetos para sua diferenciação e classificação, indo além das características espectrais dos alvos. Desta forma, passa a ser possível integrar no processo de classificação dados de outras origens (não só as imagens), determinar limiares *fuzzy* (não booleanos), hierarquizar geometrias e itens de legenda, entre outros (BLASCHKE, 2010; SEABRA; CRUZ, 2014).

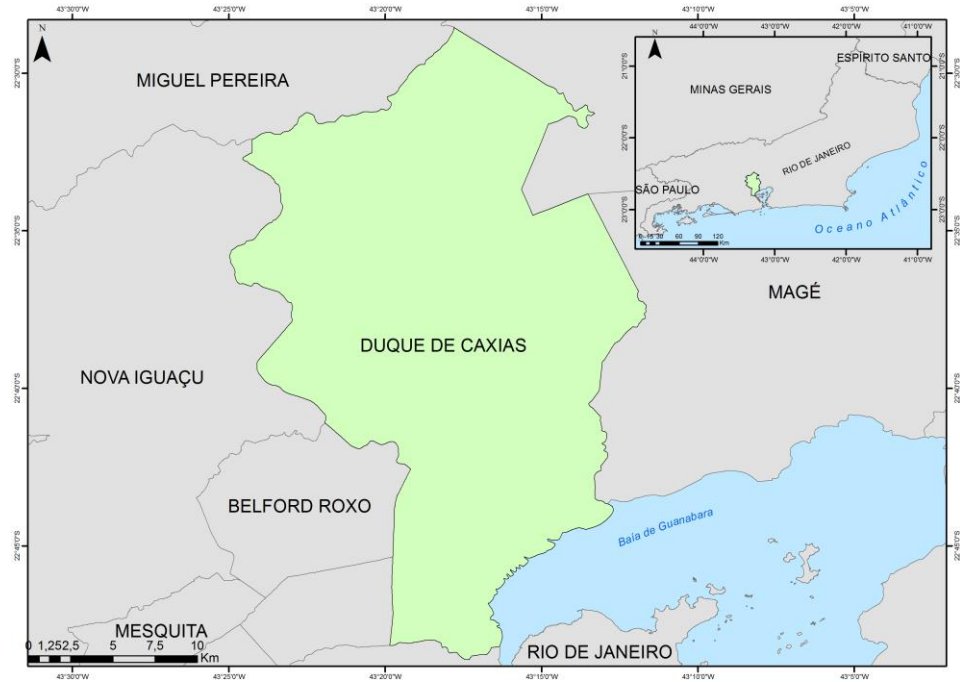
Nesta perspectiva, o presente trabalho tem como proposta explorar algumas abordagens práticas sobre o processo de classificação de imagens baseada em objetos integrada com SIG, com o intuito de gerar um produto temático de cobertura da terra a nível municipal, utilizando para isso uma cena do sensor OLI transportado pelo satélite Landsat 8. Além disso, foram empregadas técnicas de

pré-processamento como a correção atmosférica, com o intuito de uniformizar algebricamente a sensibilidade dos detectores do sensor e reduzir os efeitos atmosféricos de espalhamento e a absorção (PONZONI *et al.*, 2015).

ÁREA DE ESTUDO

O referencial empírico escolhido para este trabalho foi o município de Duque de Caxias ($22^{\circ}47'08''S$, $43^{\circ}18'42''W$) situado na mesorregião metropolitana do Rio de Janeiro (Figura 2). Com uma área territorial de 467, 620km² o município, segundo a Lei n.º 2.157, de 28-05-1954, está dividido em 4 distritos: Duque de Caxias, Campos Elyseos, Imbariê e Xerém. Compreendido em seu território, estão importantes unidades de conservação como a Reserva Biológica do Tinguá, a APA Petrópolis, a Reserva da Marinha do Brasil e a APA São Bento. Junto a essas unidades de conservação em áreas de Mata Atlântica estão áreas de manguezais na faixa litorânea de frente para a Baía de Guanabara. As atividades primazes estão ligadas ao setor terciário e a demanda de atividades oriundas do polo petroquímico da refinaria REDUC.

Figura 2 – Localização da área de estudo – município fluminense de Duque de Caxias



CONCEITOS

Tendo em vista que o objetivo deste trabalho é apresentar uma abordagem fundamentalmente embasada por experimentos práticos, a breve discussão teórica tem como propósito apenas situar o leitor sobre alguns conceitos muito citados no corpo deste trabalho.

CORREÇÕES ATMOSFÉRICAS

A correção atmosférica tem por objetivo, corrigir distorções que distanciam as curvas espectrais da radiância aparente da realidade espectral dos objetos imageados, permitindo assim, acessar as propriedades espectrais desses objetos. Esse acesso é denominado “caracterização espectral” e a partir dela é possível correlacionar a radiometria da imagem com as propriedades geofísicas e/ou biofísicas dos objetos. É possível, ainda, realizar operações aritméticas com as imagens, uma vez que os dados existentes em imagens adquiridas em faixas espectrais distintas estarão em uma mesma escala. Então operar-se-á com dados em uma mesma unidade, o que não acontecia quando em números digitais (NDs).

Feita a conversão de NDs em valores de radiância aparente, torna-se possível a comparação de dados de diferentes faixas espectrais de um mesmo sensor e até de sensores diferentes, mas com a limitação onde os valores de radiância estão ainda influenciados pela ação de dois efeitos da atmosfera: o espalhamento e a absorção. O espalhamento é mais marcante na região espectral do visível, enquanto que nas regiões do infravermelho próximo e do infravermelho médio a absorção é mais influente. Assim, sob estes efeitos, pode-se esperar dos valores de radiância (efetivamente medida pelo sensor sobre a faixa espectral) ou de radiância aparente é que estes devem estar superestimados em imagens referentes à região do visível e subestimados nas regiões do infravermelho próximo e infravermelho médio (PONZONI *et al.*, 2014; PONZONI *et al.*, 2015).

ANÁLISE DE IMAGENS BASEADA EM OBJETOS GEOGRÁFICOS (GEOBIA)

Seabra e Cruz (2014) apontam que a classificação de imagens baseada em objetos geográficos busca simular técnicas de interpretação visual, através da modelagem do conhecimento, para identificação de feições que têm uma existência concreta no mundo real, baseando-se na descrição de padrões identificadores, tais como textura, cor, tamanho, forma, localização, padrão e contexto. Dentro da lógica dos autores citados, a classificação de imagens baseada em objetos tem como intuito preencher as lacunas dos tradicionais classificadores baseados somente nos atributos espectrais, que não permitiam o uso de dados de diferentes resoluções e outros dados temáticos, como dados vetoriais.

A fundamentação do processo de (GEOBIA) parte dos sistemas baseados em conhecimento, definidos como aqueles que modelam em um ambiente computacional o conhecimento do foto-intérprete emulando a sua capacidade de combinar dados de diferentes fontes e formatos na análise de imagens de sensores remotos. Sistemas como esses abrem a possibilidade de extração automática de informações de imagens de Sensoriamento Remoto que torna esse processo mais dinâmico para as inúmeras temáticas existentes nas ciências ambientais (PINHO, 2005; SOUSA, 2013).

O objeto vem a ser um elemento do mundo real que possui atributos que são identificados através do conhecimento das suas características. Pode ser definido no meio computacional através de operações aplicadas com base na construção de procedimentos que definem o seu tamanho em uma imagem. O

tamanho médio dos objetos é medido através de uma função denominada de parâmetro de escala, que se trata de um número sem unidade, que define a heterogeneidade máxima permitida dentro dos objetos (SOUSA, 2013).

Esses objetos possuem características que são identificadas pela cor, textura, tamanho, forma, padrão, localização e contexto, descritas por Pinho (2005) e apresentadas na Tabela 1.

Tabela 1 - Definições das propriedades encontradas nos objetos em GEOBIA

Características	Definição
Cor	Resultado da combinação da resposta dos alvos em uma determinada Banda espectral e do tipo de composição colorida utilizada na imagem. Ex.: áreas com vegetação são representadas pela cor verde em composições de cor verdadeira, e na cor vermelha, em composições que utilizam o canal infravermelho.
Textura	Relaciona-se com a frequência de mudanças nos tons e cores de um objeto de imagem, variando de aspecto liso ao rugoso. Ex.: Possibilita a distinção de áreas de vegetação arbórea (textura rugosa) de áreas de vegetação rasteira (textura lisa).
Tamanho	Função da resolução espacial da imagem analisada e da dimensão dos objetos na cena. Ex.: Distingue um carro do telhado de um edifício.
Forma	É um elemento importante na distinção de formas circulares, retangulares, ovais e irregulares. Ex.: Culturas irrigadas com pivô central que se diferenciam das demais por sua forma circular.
Padrão	É o arranjo espacial de determinados objetos em uma superfície. Ex.: uma área residencial planejada pode ser distinguida de uma área de ocupação irregular pelo padrão espacial de quadras regulares.
Localização	Refere-se ao local específico onde um objeto está situado. Ex.: Identificação de determinado tipo de bioma que só ocorre em uma determinada localização geográfica.
Contexto	Posicionamento relativo de um objeto em relação a outros objetos. Ex.: Um estacionamento com pavimentação asfáltica é diferenciado de uma rodovia pelo fato de o primeiro estar localizado dentro de quadras.

Fonte: Adaptado de Pinho (2005).

A inserção das características apresentadas na Tabela 1 proporciona a inclusão do conhecimento do intérprete no processo de classificação dos objetos que são representações do mundo real. Os objetos são verificados através dessas características que servem de suporte para a construção de uma rede semântica que visa realizar a classificação por meio da modelagem do conhecimento (SOUSA, 2013). Portanto, a inserção destes elementos, ou seja, do conhecimento do intérprete no processo, consiste em uma alternativa para a distinção de alvos que espectralmente apresentam dificuldades de serem mapeados (SEABRA; CRUZ, 2014).

Em resumo um dos grandes diferenciais da GEOBIA em relação aos demais classificadores é que esse processo de classificação considera muitos tipos de descritores, apresentando a possibilidade de se realizar multissegmentações, gerando níveis hierarquizados, incluindo ainda aspectos de multirresolução (PINHO, 2005; SEABRA & CRUZ, 2014).

METODOLOGIA

MATERIAIS

Além da imagem trabalhada nesta pesquisa e dos parâmetros de correção fornecidos nos seus metadados, os materiais utilizados para realizar o pré-processamento e a análise, respectivamente, foram o módulo *ATCOR2*, do software *ERDAS IMAGINE 2014*, o software *ArcMap 10.1* e o software *eCognition 9*.

O *ATCOR2* converte os números digitais (NDs) da imagem para a radiância espectral no sensor. Para que seja feita essa conversão é utilizada uma equação linear de calibração, descrita entre os números digitais e a radiância no sensor observada em cada banda. Segundo Soares *et al.* (2015) o modelo *ATCOR (Atmospheric and Topographic Correction for Satellite Imagery)*, precisa receber como dados de entrada as condições atmosféricas no momento da aquisição das imagens utilizadas para correção. Tal técnica é baseada no modelo *MODTRAN (Moderate Resolution Atmospheric Transmission)*, um algoritmo desenvolvido pela *AFRL (Air Force Research Labs)* em colaboração com a *SSI (Spectral Sciences Inc)*, que calcula a transmitância da atmosfera em condições climáticas e ângulos solares específicos inseridos pelo próprio usuário, com a aplicação direta sobre a imagem (SOARES *et al.*, 2015). Já o software *eCognition* foi criado, prioritariamente, para atender à classificação de imagens de alta resolução espacial em abordagem baseada em objetos. A versão comercial deste programa apresenta ambiente para a classificação de imagens através da adoção de segmentação em diferentes níveis de escala, todos hierarquizados por meio da utilização de descritores variados, disponibilizados ou construídos. Além disso, o software tem a possibilidade de elaborar uma modelagem que propicia uma maior participação do intérprete, através da definição dos melhores descritores e tipos de modelos. Os modelos utilizados podem ser de origem booleana e/ou *fuzzy* que também contam com a relação entre níveis, garantindo a hereditariedade entre classes e a versão atual contou com a incorporação de um módulo para mineração de dados.

O software *ArcMap*, do pacote *ArcGIS 10.1* da *ESRI*, foi adotado não só para trabalhar simultaneamente com múltiplos arquivos vetoriais e raster, mas como a ferramenta utilizada para implementação da fusão de imagem, para gerar um buffer com do 2 km ao redor do limite territorial do município e para gerar regras em conjunto com dados altimétricos do *SRTM 30*, a fim de melhorar a classificação da imagem e gerar o mapa final de cobertura do município de Duque de Caxias.

DADOS DA PESQUISA

A pesquisa foi fundamentada em dados secundários disponibilizados por órgãos públicos de mapeamento como o *IBGE*, de onde foi extraída a base dados vetoriais dos municípios brasileiros, contendo os limites administrativos do município de Duque de Caxias como mostrado na Figura 2. Esta malha municipal encontrava-se referenciada ao datum topocêntrico *SAD 69* e foi “reprojetada” para o sistema de referência geocêntrico *SIRGAS 2000*. É importante ressaltar

que todos os arquivos gerados neste trabalho foram ajustados para o Datum SIRGAS 2000.

Quanto às imagens de sensores orbitais, o processo de classificação começou com a aquisição de uma cena do sensor OLI, transportado pelo satélite Landsat 8, no site da USGS adquirida no mês de Novembro (dia 11), do ano de 2015. A imagem OLI da área de estudos foi adquirida gratuitamente a partir do Earth Explorer (<http://earthexplorer.usgs.gov/>) disponibilizado pelo *U.S. Geological Survey*. O sensor OLI tem por característica a geração de imagens em nove Bandas espectrais, incluindo uma Banda pancromática, onde as imagens multiespectrais tem resolução espacial de 30m (exceto a pancromática com 15m) e resolução radiométrica de 12 bits. A Tabela 2 mostra em detalhes as características das Bandas e dos seus respectivos sensores a bordo do satélite Landsat 8.

Tabela 2 - Sensores e bandas do satélite Landsat 8

	Bandas	Comprimento de Onda (nm)	Resolução Espacial (m)
OLI e TIRS	Banda 1 – Azul Costeiro	0.43 - 0.45	30
	Banda 2 - Azul	0.45 - 0.51	30
	Banda 3 - Verde	0.53 - 0.59	30
	Banda 4 - Vermelho	0.64 - 0.67	30
	Banda 5 – Infravermelho próximo	0.85 - 0.88	30
	Banda 6 - SWIR 1	1.57 - 1.65	30
	Banda 7 - SWIR 2	2.11 - 2.29	30
	Banda 8 - Pancromática	0.50 - 0.68	15
	Banda 9 - Cirrus	1.36 - 1.38	30
	Banda 10 - Termal(TIRS) 1	10.60 - 11.19	100 * (30)
	Banda 11 – Infravermelho (TIRS) 2	11.50 - 12.51	100 * (30)

Fonte: Adaptado de Soares *et al.* (2015).

Segundo Kalaf *et al.* (2012) as mudanças relacionadas à resolução radiométrica da imagem não foram os únicos avanços na nova versão das imagens Landsat 8, uma vez que, nas versões anteriores, as imagens eram geradas em 8 bits. Outro importante ganho relaciona-se ao posicionamento espacial das mesmas, já que em teste realizados para o estado do Rio de Janeiro, em diferentes condições de relevo, comprovam a adequação destes produtos às escalas de 1:100.000, sem a necessidade de correções em seu posicionamento.

Para o trabalho foram adquiridas as Bandas de 1 a 7 do sensor OLI e a Banda 8 pancromática, as quais foram incorporadas ao módulo *ATCOR2* do *ERDAS* para as correções atmosféricas. As bandas 2, 3, 4 e 5 foram fusionadas no *ArcMap*, junto com a inserção da banda 8 pancromática, a fim de aumentar a resolução espacial de toda a composição. Posteriormente, as imagens foram inseridas no *software eCognition*, para posterior segmentação e classificação.

Para o processo de classificação foi adotado um buffer de 2km ao redor do limite territorial do município a fim de contornar os problemas eventuais produzidos pelo efeito de borda. Junto a ele, os dados altimétricos do SRTM 30 para o local, no formato raster, foram transformados em um arquivo *shapefile* onde cada pixel virou um polígono com valor de altitude associado a ele. Isto foi

gerado para definir regras de classificação e diminuir eventuais inconsistências ao longo do processo de classificação.

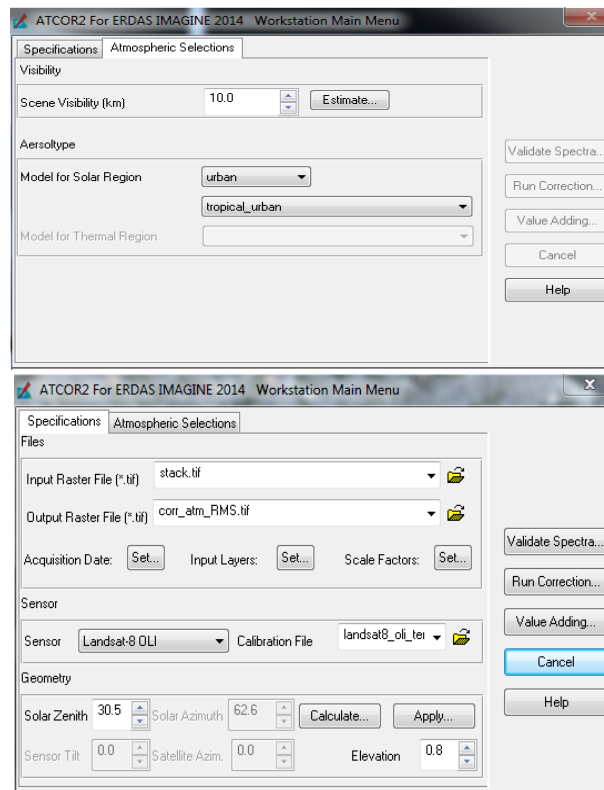
PRÉ-PROCESSAMENTO DAS IMAGENS

Inicialmente após a aquisição da cena da imagem OLI que cobre todo o município de Duque de Caxias, foi iniciado o processo de correção atmosférica da imagem com o intuito de reduzir o efeito de espalhamento exercido sobre a cena. Seguindo os experimentos de Soares *et al.* (2015), antes de iniciar a correção no ATCOR2 foi necessário fazer um *layer stacking*, no programa, com as bandas utilizadas para que elas ficassem em um mesmo arquivo tipo img. O arquivo de entrada foi o stack.tif e o arquivo de saída foi o corr_atm_UT.tif. Os parâmetros de entrada utilizados que forneceram o melhor resultado foram semelhantes da literatura citada, uma vez que foram adotados o modelo de atmosfera tropical e o modelo de aerossóis urbano, que apresentaram melhores resultados visuais, em comparação com combinações do mesmo modelo de atmosfera associado aos modelos de aerossóis marítimo e rural. O mesmo foi constatado quando o modelo de atmosfera utilizado foi o verão de média latitude, combinado os modelos de aerossóis urbano, marítimo e rural, em que o espalhamento foi menos atenuado se comparado com a combinação adotada acima e expressa na Figura 3.

O parâmetro de visibilidade estimado pelo software se deu com 10 km; a superfície média de 800m (que no software escreve-se 0.8) acima do nível do mar; o ângulo solar Zenith definido como 30.5, dentre outros dados requisitados que estão presentes nos metadados da imagem.

Com relação à escolha do parâmetro de visibilidade, uma ressalva feita por Ponzoni *et al.* (2014) torna-se muito relevante uma vez que o autor coloca que de maneira equivocada muitos usuários se servem de informação fornecida por aeroportos sobre a visibilidade na data da passagem em locais mais próximos ao da cena a ser corrigida. A visibilidade informada por aeroportos refere-se à visibilidade horizontal, muito importante no tráfego aéreo. Contudo, quando se pretende corrigir o efeito da atmosfera sobre imagens orbitais, o interesse é na visibilidade vertical que é muito difícil de avaliar. Em termos práticos, essa visibilidade pode ser escolhida também de forma arbitrária observando diferentes imagens da cena a ser corrigida, sendo todas elas do mesmo sensor.

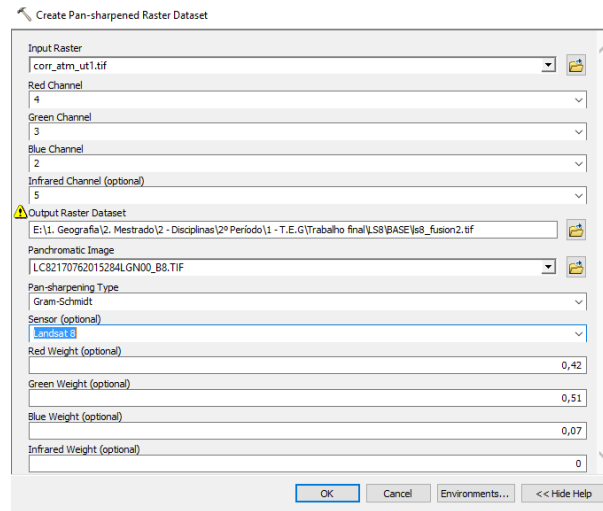
Figura 3 – Dados inseridos para o processo de correção atmosférica no módulo *ATCOR2*



SEGMENTAÇÃO E CLASSIFICAÇÃO

O processo de classificação da imagem utilizou a imagem vetorizada onde foram selecionadas quatro bandas (tendo em vista que esse é o limite do programa) para realizar o processo de fusão no *ArcGIS 10.1*. Nesse caso, as bandas do sensor OLI escolhidas foram a banda 4 vermelho, colocada no canal do vermelho, a banda 3 verde, colocada no canal do verde, a banda 2 azul, colocada no canal do azul e a banda 5 infravermelho próximo colocado no canal do infravermelho. Após definir o arquivo de saída foi colocada junto a elas a banda 8 pancromática. A adição dessa banda tem como intuito elevar a resolução espacial das bandas do visível e do infravermelho, de 30m para 15m, que vem a ser a mesma resolução espacial da Banda pancromática. Os parâmetros foram inseridos de acordo com as especificações dos metadados para o sensor selecionado (Landsat 8) como mostra a Figura 4.

Figura 4 – Processo de fusão das Bandas realizado no ArcGIS




Com a resolução espacial da imagem em 15m foi definida a área mínima do mapeamento para trabalhar com a imagem nesse processo de classificação. Como cada pixel tem o valor de 225m² a área de trabalho deve ser algo representativo que ajude na identificação de um objeto, tendo em vista que um só pixel não permite discriminar uma feição. Partiu-se do seguinte comparativo: tendo um número de pixels conhecido para a área mínima de uma imagem RapidEye que tem a resolução espacial 3 vezes maior e que utiliza 4 pixels, do que a imagem pancromática do Landsat 8, então partiu-se da premissa de que seria necessário um conjunto de pixels 3 vezes maior para se identificar um objeto em uma imagem do Landsat 8, sendo confirmado por averiguação visual na imagem trabalhada. Portanto, foram adotados 12 pixels para compor a área mínima do estudo o que corresponde a 2.700m² ou 0,0027km². Essa área corresponde a uma fração de 173.192 unidades do município de Duque de Caxias, permitindo trabalhar com uma escala de mapeamento equivalente a 1:50.000.

Após a fusão das bandas e a definição da área mínima, a imagem foi inserida no *software eCognition* para dar início ao processo de segmentação.

O processo de segmentação fez-se pelo uso do algoritmo *Multiresolution Segmentation*, onde este verifica na imagem heterogeneidades entre duas regiões, baseando-se nos atributos de cor e forma, respeitando os pesos dados pelo usuário. A soma ponderada destas heterogeneidades caracteriza a similaridade, que é a propriedade que faz com que os as regiões sejam agrupadas ou não. Este processo é interativo, como lembra Pinho (2005), repetindo-se até que toda a imagem seja segmentada em objetos.

O parâmetro de segmentação seguiu a lógica do *top-down* partindo de um nível hierárquico menos detalhado dos objetos para um nível abaixo mais detalhado. O parâmetro de segmentação de 150 foi gerado com base na segmentação de 200 de fator de escala mais detalhado (Figura 5).

Figura 5 – Segmentação com fator de escala de 200 (esquerda) e a posterior com fator de escala de 150 (direita)



Posteriormente foram definidas as cinco classes para promover o mapeamento de cobertura da terra no município de Duque de Caxias utilizando a herança de classes na árvore de decisão. As classes geradas foram: Água, Solo exposto, Urbano, Vegetação densa e Vegetação rasteira. A escolha destas classes deve-se a possibilidade identificar visualmente as classes supracitadas na escala de trabalho. Após a definição das classes de cobertura da terra para a área de estudo, foi pensada a modelagem do conhecimento com os principais descritores disponíveis.

Foi utilizada a herança na hierarquia de classes, para que uma classe-filho herde as características da classe-pai, limitando sua modelagem ao modelo da classe-pai. Este procedimento ajuda na diminuição da confusão da modelagem entre classes, pois só leva em consideração classes que pertencem àquela classe-pai.

No que diz respeito à classe água, ela foi modelada utilizando os descritores de ARITMÉTICA DE BANDAS e BRILHO. A aritmética de bandas é o resultado da divisão do número de bandas pelo seu somatório; e o brilho baixo também ajudou bastante na separação da classe água em relação a classe não-água (Figura 6).

Figura 6 – Modelagem da classe água

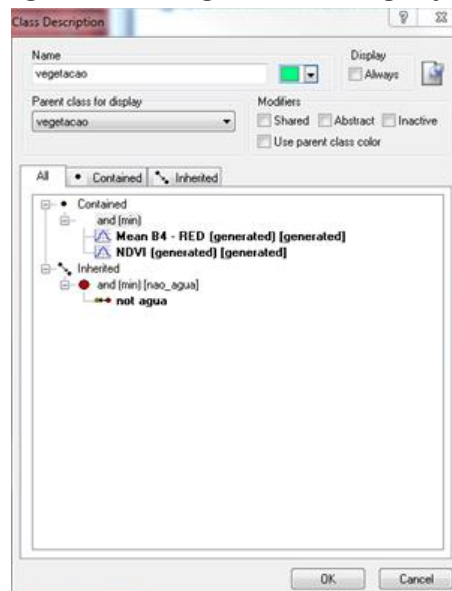


Dando continuidade, tudo que o *eCognition* não classificou como água foi agrupado na classe não-água, que não teve modelagem. A partir dela, desdobraram-se mais duas classes: vegetação e não-vegetação.

Para a classe vegetação, foram utilizados os descritores MÉDIA DA BANDA 4 (vermelho) e NDVI (Figura 7). Com as amostras selecionadas, foram feitas observações dos melhores descritores para modelagem tendo na MÉDIA DA BANDA 4 um dos que obtiveram melhor comportamento.

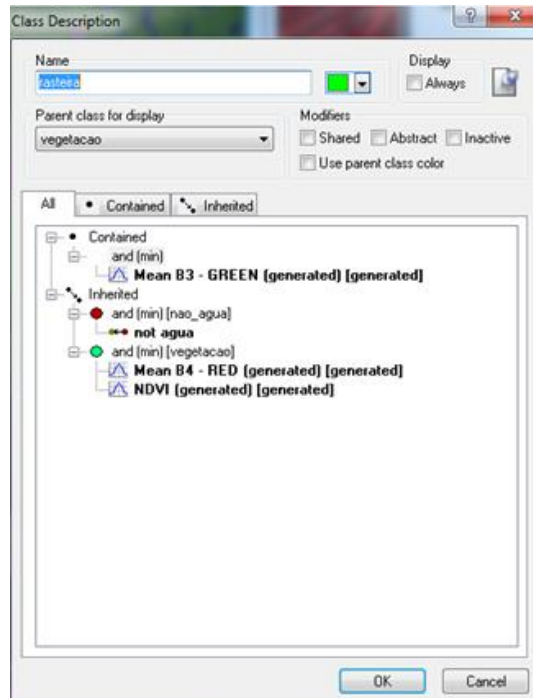
Como herdeiras da classe vegetação, estão as classes vegetação densa e vegetação rasteira. Assim como na classe-pai, tudo que não era vegetação, ou seja, que não se enquadrava nos modelos criados, foram agrupados na classe não-vegetação, que desdobravam-se em duas classes-filho: urbano e solo exposto.

Figura 7 – Modelagem da classe vegetação



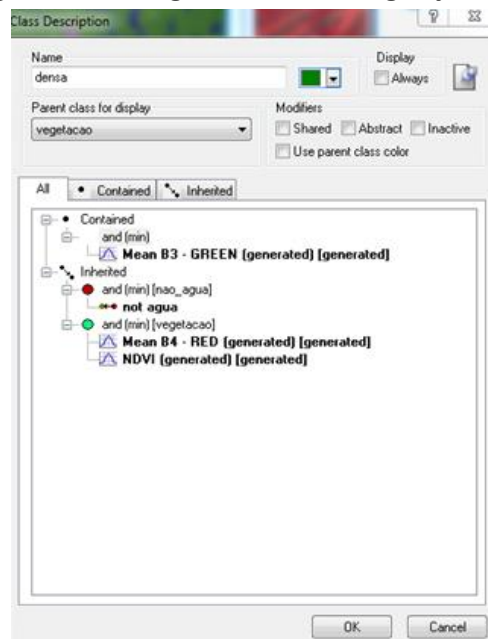
A classe vegetação rasteira (Figura 8) herdou o pertencimento às classes não-água e vegetação, portanto, com a modelagem de sua classe-pai vegetação bem feita, não haveria confusão com as classes urbano e solo exposto, classes-filhos de não-vegetação. Nesta classe, o descritor utilizado foi a MÉDIA DA BANDA 3 (verde), para separar da classe vegetação densa. Não foi encontrada muita dificuldade na separação destas duas classes.

Figura 8 – Modelagem da classe de vegetação rasteira



Da mesma forma, na classe vegetação densa, foi utilizada a MÉDIA DA BANDA 3 (verde) para a separação com a classe vegetação rasteira. Apesar de usarem o mesmo descritor, a vegetação rasteira e densa tinham respostas bem diferentes, possibilitando uma ótima separação entre elas (Figura 9).

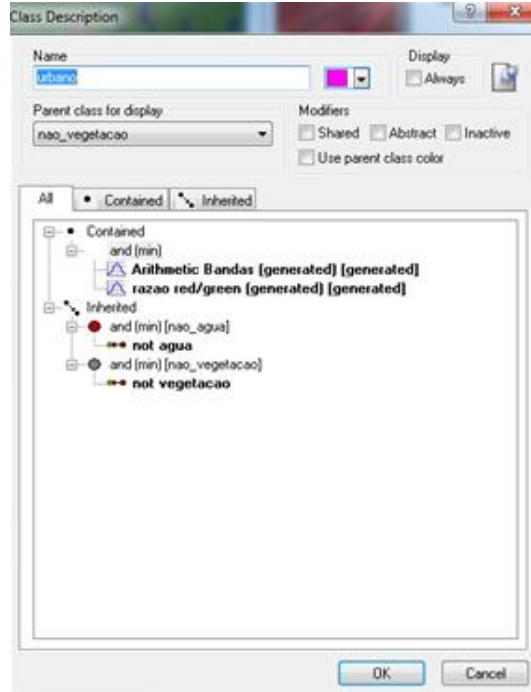
Figura 9 – Modelagem da classe de vegetação densa



A classe urbano, classe-filho de não-vegetação, teve sua modelagem um pouco mais complicada, pois confundia-se com solo exposto. Nesta classe, foram

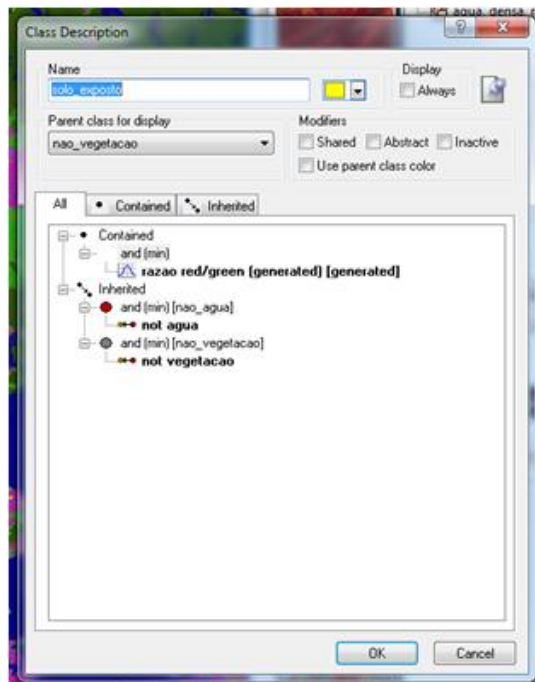
utilizados os descritores ARITMÉTICA DE BANDAS e a RAZÃO DA BANDA DO VERMELHO COM A BANDA DO VERDE (Figura 10).

Figura 10 - Modelagem da classe urbano



A classe solo exposto teve sua melhor separação da classe urbano utilizando o descritor RAZÃO DA BANDA VERMELHA PELA VERDE (Figura 11).

Figura 11 – Modelagem da classe solo exposto




Após a classificação no *eCognition*, foram exportadas todas as classes para o *ArcMap*, afim de utilizar o SRTM 30 para dar continuidade na classificação. Para tanto, foi gerado o um arquivo vetorial a partir do SRTM 30 com valor de altimetria atribuído para cada polígono. Os polígonos foram agrupados em faixas de mesma altimetria e a partir daí foi feita uma consulta espacial dos polígonos da classe água acima da faixa altimétrica de 50m, pois houve confusão entre a classe água e vegetação densa, que apresentava respostas muito parecidas na modelagem, por conta do baixo brilho. Foi gerada uma regra com base na tabela de atributos para que esses polígonos de água fossem classificados como vegetação densa.

VALIDAÇÃO DOS RESULTADOS

Para validar os resultados obtidos nesta classificação foram criados, à partir da ferramenta *Generate Random Points*, do *ArcMap 10.1*, 30 pontos aleatórios, para cada uma das classes, afim de verificar se o segmento em que o ponto estava posicionado pertencia àquela classe, de fato (Figura 12). A seguir, foi feita a verificação, ponto a ponto, averiguando se o ponto em questão pertencia à classe a qual ele foi criado ou se pertencia a outra classe do mapeamento. Essa informação era acrescentada na tabela de atributos, permitindo que, posteriormente, fosse construída uma matriz de confusão da classificação. Essas amostras que ocorreram fora do local de suas classes denunciam as inconsistências presentes no processo de classificação.

Figura 12 – Distribuição das amostras na área de estudos



Com relação a este estudo uma inconsistência bem marcante após a classificação por *GEOBIA*, foi a detecção de áreas de sombra que foram incorporadas à classe água, também associada ao baixo brilho na modelagem do conhecimento.

A validação dos dados foi obtida através da matriz de confusão (Figura 13) junto com a precisão (Figura 14) de cada classe, do coeficiente *Kappa* e da exatidão global.

Figura 13 – Matriz de confusão

		Matriz de Confusão					
Realidade \ Classificação	Vegetação densa	Vegetação rasteira	Urbano	Solo Exposto	Água	Total	
Vegetação densa	30	0	0	0	0	30	
Vegetação rasteira	0	28	1	0	1	30	
Urbano	1	0	27	1	1	30	
Solo Exposto	0	1	0	25	4	30	
Água	0	0	0	1	29	30	
Total	31	29	28	27	35	150	

Figura 14 – Precisão de cada classe do mapeamento

Precisão	
Água	96.67%
Vegetação densa	100.00%
vegetação rasteira	93.33%
solo exposto	83.33%
urbano	90.00%

A matriz de confusão é a forma de representação da qualidade obtida de uma classificação digital de imagem, sendo expressa por meio da correlação de informações dos dados de referência (compreendido como verdadeiro) com os dados classificados. Inclusive, essa rotina também pode ser expressa, pela análise das amostras de treinamento juntamente com os dados classificados. Esta última é muito utilizada em trabalhos científicos, uma vez que na maioria dos locais não existem dados de referência, sendo assim, impossível fazer a primeira analogia destacada (FONSECA, 2000).

Neste estudo a matriz de confusão mostrou que, para a classe vegetação densa, todos os 30 pontos da amostra aleatória corresponderam a essa classe. Na classe Água, 29 amostras corresponderam exatamente à classe. Quanto à classe Vegetação rasteira, 28 amostras corresponderam a esta classe. Já as classes urbano e solo exposto, tiveram as maiores discordâncias, onde urbano teve 27 acertos, confundindo-se com vegetação densa, solo exposto e água e a classe urbano com 25 acertos, confundindo-se com água (4 amostras) e vegetação rasteira (1 amostra).

O coeficiente *Kappa* é uma das variáveis que podem ser quantificadas após construir a matriz de confusão, sendo um índice que retrata o grau de concordância dos dados, gerando, assim, um aspecto de confiabilidade e precisão dos dados classificados. O resultado obtido pelo coeficiente *Kappa*, varia no intervalo de 0 a 1, sendo que quanto mais próximo a 1, melhor a qualidade dos dados classificados. Vários são os índices para agrupar esses dados quantitativos para qualitativos, entre eles, pode ser destacado o de Fonseca (2000), conforme destacado na Tabela 3.

Tabela 3 – Agrupamento qualitativo do coeficiente *Kappa*

Índice Kappa	Desempenho
< 0	Péssimo
$0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

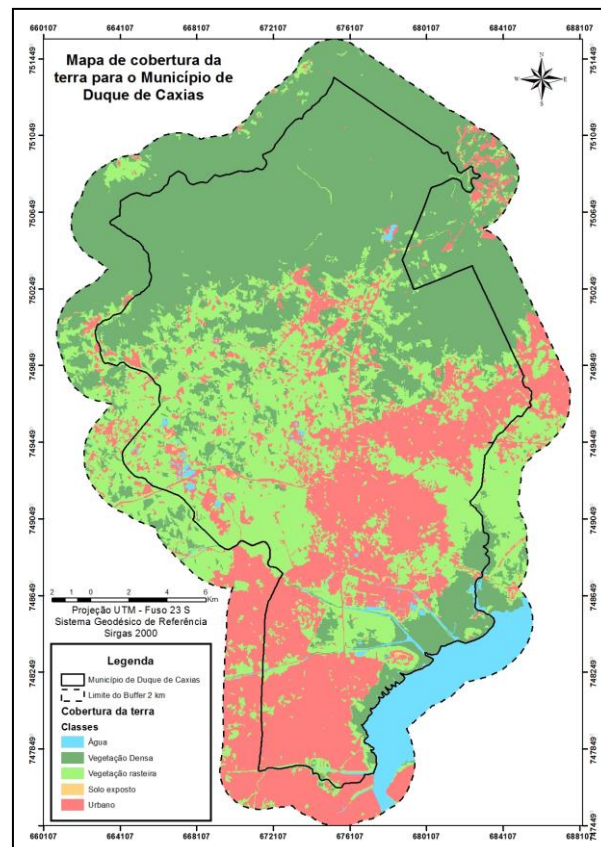
Fonte: Fonseca (2000).

O índice *Kappa* deste estudo calculado a partir dos valores da matriz de confusão chegou ao valor de 0.9083 ou 90,83%, enquadrando-se no que é considerado excelente para este processo de classificação (FONSECA, 2000).

A exatidão global é calculada dividindo a soma da diagonal principal da matriz de erros x_{ij} , pelo número total de amostras coletadas (n amostras). A distribuição da precisão ao longo das categorias individuais não é apresentada na precisão global, entretanto a precisão de uma categoria individual é obtida através da divisão do número total de amostras classificadas corretamente naquela categoria pelo número total de amostras da mesma categoria (CONGALTON & GREEN, 2009).

O valor encontrado para a exatidão global foi de 93%, que aliado ao resultado do coeficiente *Kappa* de 90,83%, tido como excelente mostrando que os resultados foram satisfatórios na geração desse produto temático, como consta na Figura 15.

Figura 15 – Mapa final de cobertura da terra no município Duque de Caxias/RJ



CONSIDERAÇÕES FINAIS

O uso da imagem landsat 8 atendeu ao propósito do trabalho em realizar o mapeamento de cobertura da terra do município de Duque de Caxias. As limitações do *software ArcMap 10.1* em permitir apenas a fusão de quatro bandas espectrais à banda pan-cromática não afetaram o desenvolvimento do trabalho, pois as bandas selecionadas (RGB e NIR) atenderam a etapa de modelagem do conhecimento e os índices criados a partir destas bandas espectrais permitiram a modelagem do conhecimento para cada classe, onde foi possível separar as mesmas.

A modelagem em questão não considerou a classe de sombras e, desta forma, os segmentos com menor brilho ficaram prejudicados na classificação, sendo interpretados como água. Assim, a utilização do modelo SRTM para criar um critério baseado na altimetria configurou-se como eficaz. A partir disto, foi possível identificar e editar de forma manual estes polígonos.

Como já apresentado anteriormente, a integração entre SIG e Sensoriamento Remoto é uma forma extremamente eficiente para o processo de classificação de imagens baseada em objetos, tendo em vista a qualidade do produto temático gerado. O índice de exatidão global e o coeficiente *Kappa* permitem inferir que a modelagem, ainda que com dificuldades para identificar sombras e outras áreas, foi bastante satisfatória. É importante salientar que a maior confusão entre classes apresentada entre solo exposto e água. É possível atribuir tal resultado a correção atmosférica realizada, que pode não ter atendido a essas classes. Desta forma, pretende-se, em trabalhos futuros, investigar este problema utilizando outros parâmetros para correção atmosférica, assim como outros descritores para modelagem do conhecimento.

Integration analysis between Remote Sensing and GIS in classifying Duque de Caxias's (RJ) land cover

ABSTRACT

The Geographic Object Based Image Analysis, also known as GEOBIA, is one of the more promising areas in Remote Sensing and Digital Image Processing research. In this perspective, this paper propose to explore approaches about GEOBIA integrated with GIS, in order to generate a land cover map of the municipality of Duque de Caxias/RJ, using a image from OLI sensor of Landsat8 satellite. The image used was submitted to atmospheric correction using ATCOR2 module and later a fusion of its RGB bands with thepanchromatic band was performed. The segmentation was made with Multiresolution segmentation and the classification key: dense vegetation; grass; urban; bare soil; and water. After mapping validation generated by knowledge modeling, the following results were obtained for Kappa index (90.83%), overall accuracy (93%) and class accuracy, where the lowest result was bare soil, with 83.33%. It is understood that OLI/Landsat8 image is a good product to classify in a municipality level. In addition, the integration GIS/Remote Sensing is an alternative to the difficulties faced in knowledge modeling.

KEYWORDS: Integration GEOBIA & GIS. Land Cover Mapping. DEM. SRTM.

AGRADECIMENTO

O primeiro autor agradece a CAPES pelo financiamento de sua bolsa de mestrado.

O terceiro autor agradece ao CNPq pelo financiamento de sua bolsa de mestrado.

O último autor agradece a CAPES/EMBRAPA pelo financiamento de sua bolsa de doutorado.

Todos os autores agradecem ao Prof. Dr. Manoel do Couto Fernandes do Departamento de Geografia da UFRJ, por suas orientações e por todo seu empenho dedicado a nossa formação como futuros pesquisadores.

REFERÊNCIAS

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Nº 65, 2010. p. 2-16.

BLASCHKE, T.; GLASSER, C. & LANG, S. Processamento de Imagens num Ambiente Integrado SIG / Sensoriamento Remoto – Tendências e Consequências. *In*: BLASCHKE, T. & KUX, H. J. F. **Sensoriamento Remoto e SIG Avançados**. São Paulo: Oficina de Textos, 2007. p. 11-18.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 2009. 192p.

EHLERS, M. Sensoriamento Remoto para Usuários de SIG – Sistemas de Sensores e Métodos: entre as exigências dos usuários e a realidade. *In*: BLASCHKE, T. & KUX, H. J. F. **Sensoriamento Remoto e SIG Avançados**. São Paulo: Oficina de Textos, 2007. p. 19-38.

FONSECA, L. M. G. **Processamento digital de imagens**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

KALAF, R.; BRASILEIRO, R.; CARDOSO, P. V.; CRUZ, C.B.M. LANDSAT 8: Avanços para Mapeamentos em Mesoescala. **Anais da 2ª Jornada de Geotecnologias do Estado do Rio de Janeiro**. Rio de Janeiro. 2012. 4p.

PINHO, C. M. D. **Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos**. (INPE-14183-TDI/1095). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2005. 180 p.

PONZONI, F. J.; MACARRINGUE, L. S.; SANTOS, S. B. & SANTOS Jr., J. L. Comparação Entre Fatores de Reflectância Gerados a Partir de Dados dos Sensores TM/Landsat 5 e MODIS/Terra Aplicando Diferentes Metodologias de Conversão de Dados. **Revista Brasileira de Cartografia**, 66 (2), 2014. p. 263-270.

PONZONI, F. J.; PINTO, C. T.; LAMPARELLI, R. A. C.; ZULLO Jr., J. & ANTUNES, M. A. H. **Calibração de Sensores Orbitais**. São Paulo: Oficina de Textos, 2015. 96p.

SEABRA, V. S & CRUZ, C. B. M. Uso do Sensoriamento Remoto na Avaliação de Alterações dos Estados Dinâmicos da Paisagem da Bacia Hidrográfica do Rio São João. **Revista Brasileira de Cartografia**, 66 (2), 2014. p. 303-320.

SOARES, F. M.; ALMEIDA, R. K.; RUBIM, I. B.; BARROS, R. S.; CRUZ, C. B. M.; MELLO, G. V. & BAPTISTA NETO, J. A. Análise comparativa da correção atmosférica de imagem do Landsat 8: o uso do 6S e do ATCOR2. In: **Anais do Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE. p.1821-1828.

SOUSA, G. M. **Modelagem do Conhecimento Aplicada ao Estudo da Susceptibilidade à Ocorrência de Incêndios no Parque Nacional do Itatiaia**. Tese (Doutorado em Geografia) – Programa de Pós-Graduação em Geografia da UFRJ, Rio de Janeiro. 2013. 161p.

Recebido: 03 mai. 2016

Aprovado: 21 fev. 2017

DOI: 10.3895/rbgeo.v5n1.5503

Como citar: ANTUNES, F. S.; NEVES, L. V.; SANTOS, K. S.; SALOMÃO GRAÇA, A. J. Análise da integração entre Sensoriamento Remoto e SIG na classificação da cobertura da terra em Duque de Caxias/RJ. **Rev. Bras. Geom.**, Curitiba, v. 5, n. 1, p. 082-102, jan/mar. 2017. Disponível em: <<https://periodicos.utfpr.edu.br/rbgeo>>. Acesso em: XXX.

Correspondência:

Fernando de Souza Antunes

Avenida Athos da Silveira Ramos, Cidade Universitária, CEP 21941-916, Rio de Janeiro, Rio de Janeiro, Brasil.

Direito autoral: Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

