

## **Classificação da Ocupação Urbana por meio de imagens orbitais no suporte ao monitoramento em mesoescala (1: 100.000) com o auxílio da mineração de dados**

Julia Silva de Queiroz Lourenço<sup>1</sup>  
Carla Bernadete Madureira Cruz<sup>1</sup>  
Elizabeth Maria Feitosa da Rocha de Souza<sup>1</sup>  
Rafael Silva de Barros<sup>1</sup>

<sup>1</sup> Universidade Federal do Rio de Janeiro – UFRJ/CCMN  
Av. Athos da Silveira Ramos, 274 - Edifício do Centro de Ciências Matemáticas e da  
Natureza, Bloco D, Cidade Universitária, Rio de Janeiro - RJ.  
Telefones: (21) 2562-9400 / 9401  
{julialourencoufrj; carlamad; elizabethmfr; barros.rafael}@gmail.com

**Abstract.** Currently there is a great demand for mappings to support environmental and phenomena monitoring of the most varied origins. Geotechnology has given the necessary support in generating coverage maps from satellite images. The GEOBIA has contributed to the development of new mappings since 2000 and requires extensive knowledge of the area of study and statistical descriptors to better differentiate the mapping classes. Thus the aim of this work is to contribute to the classification of urban areas in mesoscale mapping with support of data mining, using based objects classifiers through a case study of the West Zone of the city of Rio de Janeiro. To this end, we used two satellite scenes LANDSAT5/TM (2000 and 2010) in order to verify the capability of replicating the classification model generated from data mining for years which were compatible with Demographic Census. During the stage of data mining, the used software was Weka 3.6. The descriptors suggested by data mining were NDVI, NIR's average (near infra-red), blue's and green's average which were entered into the software Definiens 7.0 to allow based on objects classification, of both dates. Based on the area's calculation, were found some superestimated classes as Urban low intensity. Global accuracy revealed 66,11% accuracy in 2010 mapping. Of the three levels of urban occupation, the High Intensity was the one that obtained the highest accuracy (63,33%) and Vegetation and Water were among all classes (100% e 86,66), those who had higher accuracy due to generalization and homogeneity respectively.

**Palavras-chave:** GEOBIA, environmental and phenomena monitoring, data mining, Análise de Imagem Geográfica baseada em objetos, monitoramento ambiental e de fenômenos, mineração de dados.

### **1. Introdução**

As técnicas de sensoriamento remoto têm se tornado cada vez mais, grandes aliadas dos estudos que envolvem mapeamento e monitoramento de áreas e fenômenos. Essa demanda parte de instituições focadas em diferentes áreas de atuação, sejam elas de natureza pública ou privada. Por outro lado, a popularização das geotecnologias nos últimos 10 anos, crescentemente marcada pela disponibilização de dados geoespaciais, tais como imagens de satélite (em alguns casos de forma gratuita como as do satélite Landsat5/TM), bases cartográficas, mapas temáticos, entre outros dados, tem viabilizado ainda mais estudos e rotinas de mapeamento e monitoramento. Considerando ainda o panorama nacional, carente de mapas atualizados e em diferentes níveis de detalhe, passa a ser fundamental que investimentos sejam feitos para que a produção de mapas possa se dar de forma mais ágil e sistemática, de modo a que a continuidade destas ações possa ser mantida.

O mapeamento de cobertura e uso da terra é um processo que envolve uma complexidade que lhe é característica devido à necessidade muitas vezes da compatibilização tanto de escalas quanto de legendas, além de poder atender a diversos estudos que envolvem temáticas distintas. Segundo consta no Manual Técnico de Uso da Terra (IBGE, 2ª edição), o levantamento sobre Cobertura e Uso da Terra comporta análises e mapeamentos e é de grande utilidade para o conhecimento atualizado das formas de uso e ocupação do espaço, constituindo importante ferramenta de planejamento e de orientação à tomada de decisão. É esperado, ainda, que os dados levantados de Cobertura e Uso da Terra fiquem disponíveis ao maior número de usuários possíveis. Também é desejável que as escalas dos mapeamentos

atendam a diferentes demandas, variando em detalhamento, tanto espacial quanto de legenda, indo de um nível local até escalas menores, mais generalizadas.

Atualmente, no que diz respeito à elaboração do mapeamento de cobertura e uso da terra, ressalta-se a importância do GEOBIA, a Análise de Imagem Geográfica Baseada em Objetos, na fase de interpretação da imagem digital. Para que seja bem aproveitada, a abordagem de classificação GEOBIA necessita do conhecimento prévio dos elementos/classes que compõem a área de estudo, para que os descritores estatísticos que melhor diferenciam as classes de interesse possam ser selecionados e modelados. Diante dessa questão, fazem-se necessários investimentos metodológicos que possibilitem a ampliação do conhecimento em prol de uma maior automatização com níveis de exatidão satisfatórios para os mapeamentos de cobertura e uso da terra. Neste sentido, este trabalho avalia o uso da técnica de mineração de dados, recentemente aplicada ao sensoriamento remoto, como um instrumento de análise para a seleção dos descritores estatísticos e/ou texturais que melhor definam a legenda de classificação, agregando, assim, conhecimento ao processo de mapeamento.

Segundo Novo (2010), o processo de atribuir um significado a um pixel de acordo com suas propriedades numéricas é chamado genericamente de classificação. Isto significa, em última análise, que a classificação associa um rótulo a cada pixel da imagem em função das suas propriedades espectrais e/ou espaciais, estejam eles agregados ou não em regiões homogêneas. As primeiras classificações automáticas de imagens de sensoriamento remoto (SR) consideravam exclusivamente os valores de nível de cinza, ou seja, o número digital armazenado em cada pixel. No início da década de 1980, as técnicas de classificação de imagens de SR foram sendo aprimoradas, e novos métodos de classificação baseados em regiões, e não mais no pixel, foram concebidos. As regiões eram conjuntos de pixels contíguos, que possuíam semelhança espectral interna, estabelecida pelo usuário a partir da definição de parâmetros. O processo de classificação ainda poderia ser categorizado em supervisionado e não supervisionado. As técnicas supervisionadas partem do pressuposto que o usuário tem conhecimento da localização de amostras caracterizadoras das classes temáticas de interesse. Logo, nestes casos, o usuário fornece ao software não somente amostras das classes, mas também uma legenda pré-definida. A fase da coleta de amostras é chamada em muitos softwares de treinamento. As técnicas não supervisionadas partem do pressuposto oposto, pois nesse caso o usuário não possui conhecimento para selecionar amostras na área de estudo, e nestes casos o software classifica os pixels ou regiões da imagem em um conjunto de classes espectrais não especificados previamente, apenas agrupando pixels ou regiões espectralmente semelhantes.

Foi somente no início dos anos 2000 que surge essa nova abordagem para a classificação e interpretação de imagens de SR, o GEOBIA. Essa nova abordagem, que surge fortemente ancorada no paradigma da Orientação a Objeto (OO), amplia o poder do especialista no processo de classificação, abrindo horizontes ainda não explorados. O processo passa a ser baseado em objetos, que podem ser entendidos como instâncias de uma classe, enquanto cada classe é entendida como um conjunto de objetos similares entre si. As características de um objeto passam a ser seus atributos e os métodos que são utilizados para manipular seu comportamento são os descritores e regras que os definem (Plataforma Definiens 7.0). Tais elementos ou parâmetros são na verdade, estatísticas calculadas para cada objeto da imagem, como por exemplo, o desvio padrão, a média, o brilho, a textura, a forma, entre outros.

### **1.1 Mineração de Dados**

A mineração de dados se incorpora ao processo de classificação entre as etapas de segmentação e seleção preliminar de descritores considerados interessantes para a determinação das classes definidas, e a classificação em si. A mineração, neste caso, busca cumprir a função de seleção de descritores e estruturação de uma árvore de decisão a partir de um conjunto de amostras selecionado pelo intérprete. A possibilidade de contar com o auxílio

de um algoritmo de mineração de dados é extremamente relevante, pois pode otimizar o processo de modelagem, normalmente árduo e demorado.

A mineração de dados é, na verdade, um processo computacional realizado através de métodos inteligentes e automatizados que tem por objetivo a extração de conhecimento dentro de grandes bases de dados. O modelo classificatório derivado da mineração pode ser representado através de diversas formas, entre elas, a árvore de decisão, que é representada por uma estrutura hierárquica que é facilmente convertida em regras de classificação, sendo esta a forma de representação recentemente adotada em sensoriamento remoto.

O presente trabalho adotou o sistema Weka 3.6, de disponibilidade gratuita, como minerador de dados. Esse software foi desenvolvido pela Universidade de Waikato, na Nova Zelândia, e tem se tornado, nos últimos anos, o minerador de dados mais utilizado no meio acadêmico. O software Weka é alimentado por uma tabela manipulada no Excel, que deve estar no formato “.CSV”, onde: as linhas são os objetos ou segmentos de análise (amostras) e as colunas são os métodos ou descritores estatísticos. A partir da leitura dessa tabela, o Weka gera uma árvore de decisão com as regras de classificação hierarquizadas. A representatividade e desempenho final desta árvore é profundamente dependente da segmentação adotada, das amostras e dos descritores previamente selecionados.

## 1.2 Área de Estudo

As áreas urbanas das cidades são áreas extremamente dinâmicas, estando em constantemente processo de expansão horizontal e vertical (intensificação). A Zona Oeste da cidade do Rio de Janeiro (Figura 1), área de estudo desse trabalho, é um exemplo de área que tem crescido de forma muito acelerada nos últimos anos, tendo sofrido com isso mudanças importantes e significativas.

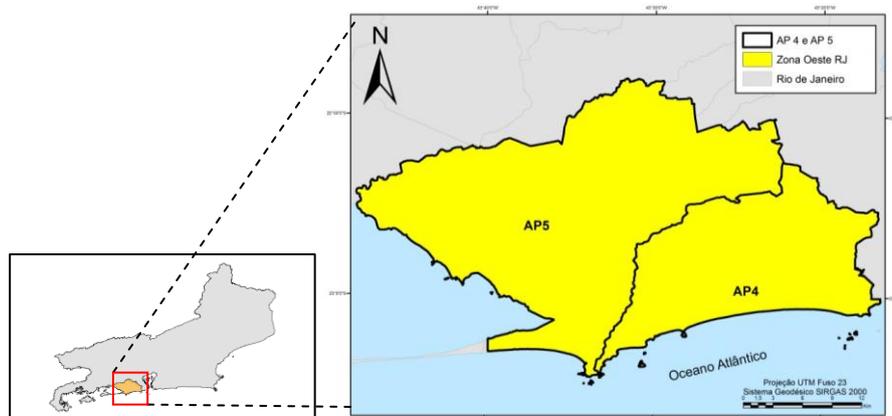


Figura 1. Área de Estudo

A Zona Oeste abriga duas Áreas de Planejamento (AP 4 e AP 5), 8 Regiões Administrativas (RA), e 39 bairros, além de corresponder à cerca de 70,5% da área total do município do Rio de Janeiro. A seguir tem-se um gráfico que representa as taxas de crescimento das 5 áreas de planejamento do Município do Rio de Janeiro. Diante desses dados é possível ver um crescimento mais representativo das APs 4 e 5 (Zona Oeste), em comparação com as outras APs (Figura 2).

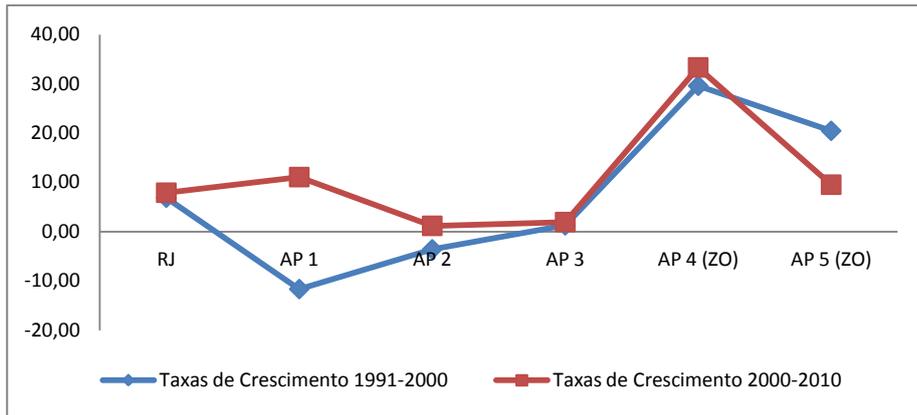


Figura 2. Taxas de crescimento por APs.

Diante disso, o objetivo do presente trabalho é contribuir para a classificação de áreas urbanas em mesoescala de mapeamento com o suporte da mineração de dados e de classificadores baseados em objetos através de um estudo de caso para a Zona Oeste do Rio de Janeiro, visando uma maior automatização do processo de mapeamento.

## 2. Materiais e Métodos

A metodologia se inicia pela aquisição das imagens do satélite Landsat 5 (TM) para os anos de 2000 e 2010 através do site do INPE/DGI. As imagens selecionadas estão associadas a um mesmo período do ano a fim de minimizar diferenças sazonais. Em seguida foi realizada a correção geométrica de ambas as cenas no software SPRING 5.2.1, tomando como dado de referência a base de logradouros do município do Rio de Janeiro, cedida pelo Instituto Pereira Passos (IPP). A primeira cena a ser corrigida foi a mais recente, de 2010. A cena referente ao ano 2000 foi corrigida a partir da imagem de 2010, de forma a garantir um melhor ajustamento entre datas.

As imagens corrigidas foram incorporadas a um projeto no sistema Definiens Developer 7.0, aonde passaram pelo processo de segmentação e amostragem (legenda estabelecida previamente). O processo de segmentação (Figura 3), que divide a imagem em inúmeros objetos ou segmentos de áreas distintas, mas com semelhança espectral interna, foi parametrizado por: parâmetro de escala 10 (diretamente associado ao tamanho do segmento), peso 0.1 para forma (o que resulta em um maior peso para cor) e 0.5 para compacidade. Para esses dois últimos parâmetros utilizou-se os valores default.

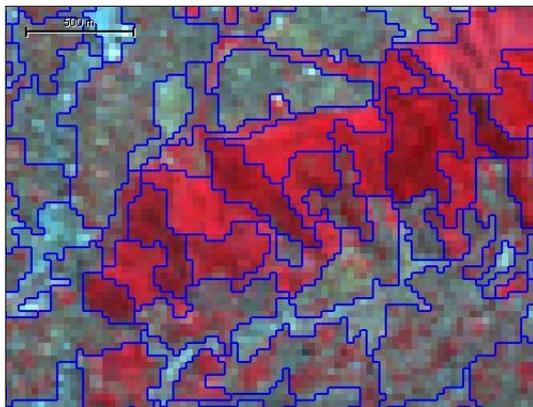


Figura 3. Segmentação da imagem Landsat 5/TM. Composição 4R3G2B.

O processo de amostragem ou treinamento foi feito com o auxílio do Google Earth, considerado satisfatório para a escala final, 1:100.000. O uso de imagens de alta resolução facilitou o treinamento dos padrões dos diferentes níveis de intensidade de ocupação. Foram coletadas entre 20 e 30 amostras por classe de interesse e estas foram exportadas na forma de tabela juntamente com uma gama de 21 descritores estatísticos (brilho, entropia GLCM-todas as direções, entropia bandas 1, 2, 3, 4, 5 e 7, máxima diferença, média das bandas 1, 2, 3, 4, 5 e 7, e desvio padrão das bandas 1, 2, 3, 4, 5 e 7). Essa tabela foi inserida no minerador de dados Weka 3.6, onde foram selecionados os descritores que melhor diferenciariam as classes de mapeamento, de acordo com os valores apresentados. Posteriormente o Weka disponibilizou uma árvore de decisão em forma de fluxograma que apresentava as regras de classificação (descritores estatísticos e seus limiares) que deveriam ser consideradas no processo de classificação para a imagem de 2010. Essas regras de classificação foram implementadas no Definiens 7.0, através da criação de uma rede semântica e dos processos correspondentes a cada nível de classificação.

O resultado obtido foi validado através de pontos selecionados de modo aleatório estratificado, para o mapeamento de 2010. A análise final considera a exatidão global do mapeamento e a exatidão por classe mapeada.

Com o objetivo de se verificar o potencial de replicação do modelo classificatório sugerido pelo minerador de dados, o mesmo foi aplicado diretamente na imagem referente à data pretérita de 2000, da mesma área de estudo. Os resultados foram avaliados mediante o cálculo das áreas por classe para ambas as datas.

A legenda adotada para a classificação contempla 7 classes de mapeamento: Água, Solo Exposto, Vegetação Densa, Vegetação Rasteira, Ocupação Urbana de Alta, Média e Baixa Intensidade. As classes de Vegetação foram agrupadas em uma única classe denominada Vegetação. Na Figura 4 estão representadas as diferentes classes de Intensidade de Ocupação Urbana mapeadas.

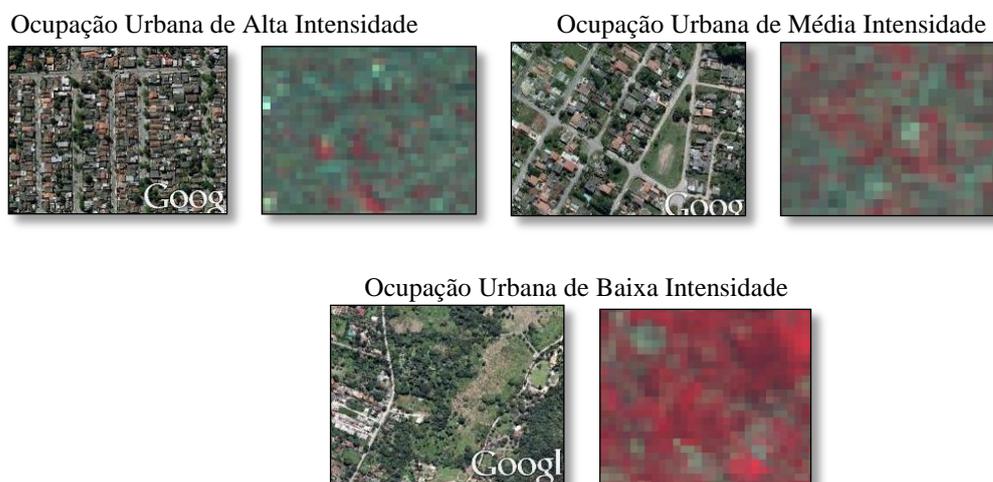


Figura 4. Classes de Ocupação Urbana.

Na Figura 4 tem-se à esquerda recortes amostrais retirados do Google Earth, enquanto à direita tem-se as mesmas áreas provenientes da imagem Landsat 5, na composição 4R3G2B. Esses exemplos representam amostras coletadas para cada classe.

### 3. Resultados e Discussão

O primeiro resultado obtido consiste na árvore de decisão, representada na Figura 5 como um fluxograma de regras e descritores com estrutura de árvore.

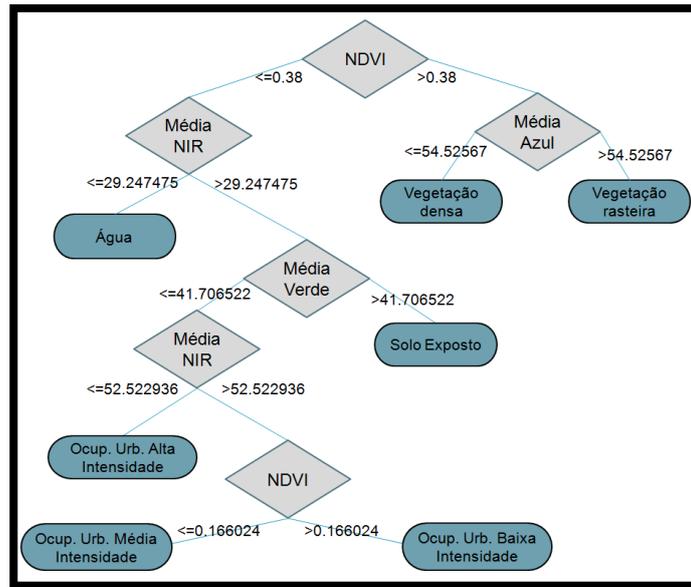


Figura 5. Árvore de decisão gerada pelo Weka.

Cada losango é uma regra ou um método (descriptor estatístico) e cada elipse é uma classe de mapeamento. Os valores intermediários entre as regras ou entre as regras e as classes são os valores das estatísticas calculadas baseadas na resposta espectral dos alvos pertencentes a cada classe. A rede hierárquica busca garantir a herança de regras entre classes pai-filho. Classes de um mesmo nível foram caracterizadas por diferentes descritores. Observando a árvores de decisão pode-se verificar que no primeiro nível hierárquico é selecionado como descriptor o NDVI criado através de uma operação entre bandas. Pela árvore, foi sugerido como limiar de corte o valor de NDVI de 0,38, onde valores superiores a este limiar seriam considerados como representativos de área de vegetação.

O uso da árvore de decisão contribuiu com a diminuição do tempo gasto no processo de classificação (Figura 6), dado que a modelagem manual é bastante complexa e demanda bastante tempo. Apesar de não ter sido implementada, sugere-se consorciar o uso de mineração de dados com a modelagem manual de descritores, de modo a alcançar uma maior exatidão no mapeamento final. Somente ao final, deve-se investir na edição manual para diminuir confusões entre classes.

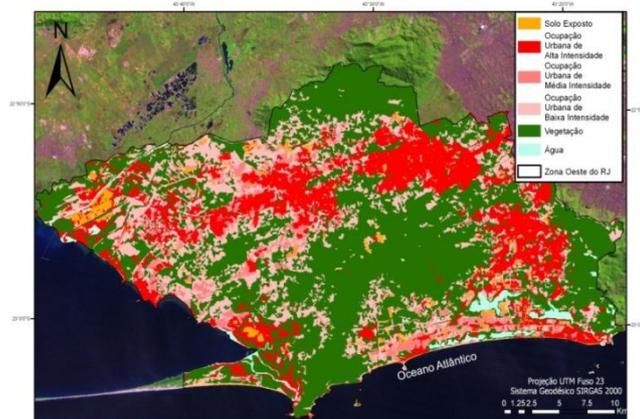


Figura 6. Classificação de Cobertura e Uso da Terra da Zona Oeste do RJ – 2010

A fim de verificar a eficácia do modelo aplicado na imagem de 2010, foi calculada a exatidão do mapeamento tanto global quando por classes de cobertura e uso da terra, através da matriz de erro, que é a forma mais utilizada para representar a exatidão da classificação

(Fidalgo, 1995 *apud* Novo, 2010). Na matriz de erro, é feita a comparação do mapa derivado da imagem com um mapa de referência, nesse caso informações do Google Earth. Para a validação foram utilizados 180 pontos, que se distribuíram igualmente pelas 6 classes. O resultado obtido para o mapa de 2010 foi de 66,11% de exatidão global, que está representado na Tabela 1.

Tabela 1. Matriz de Erro – 2010

Dados de Referência (Google Earth)	Dados Classificados						Total da linha
	Água	Vegetação	Urbano Baixa Intensidade	Urbano Média Intensidade	Urbano Alta Intensidade	Solo Exposto	
Água	<b>26</b>	0	0	0	0	0	26
Vegetação	4	<b>30</b>	18	1	5	2	60
Urbano Baixa Intensidade	0	0	<b>5</b>	2	1	0	8
Urbano Média Intensidade	0	0	3	<b>16</b>	4	2	25
Urbano Alta Intensidade	0	0	4	10	<b>19</b>	3	36
Solo Exposto	0	0	0	1	1	<b>23</b>	25
Total da coluna	30	30	30	30	30	30	<b>180</b>

No que diz respeito à exatidão por classes foram obtidos os seguintes níveis de acerto: Água 86,66%, Vegetação 100%, Ocupação Urbana de Baixa Intensidade 16,66%, Ocupação Urbana de Média Intensidade 53,33%, Ocupação Urbana de Alta Intensidade 63,33% e por fim, Solo Exposto 76,66% de exatidão. O alto índice de confusão da Ocupação Urbana de Baixa Intensidade com a Vegetação se deve justamente à grande influência da vegetação no interior da Ocupação de Baixo nível de intensidade. E, o alto grau de acerto da Água e da Vegetação se deve, respectivamente, à homogeneidade característica desse tipo de alvo, e à generalização da vegetação através do agrupamento das duas classes de vegetação em apenas uma classe.

A análise da classificação obtida para o ano de 2000, portanto, apresentou resultados pouco satisfatórios. O modelo adotado não se mostrou estável o suficiente para ser aplicado em diferentes datas, conforme pode ser verificado na Figura 7 e na Tabela 2.

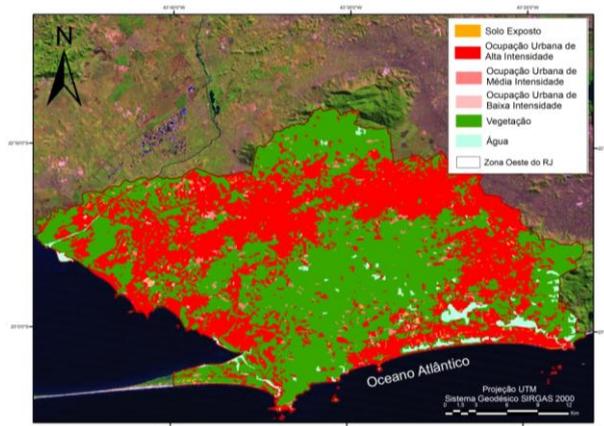


Figura 7. Classificação de Cobertura e Uso da Terra da Zona Oeste do RJ – 2000

A Tabela 2 apresenta o cálculo de áreas por classe obtidas para os 2 mapeamentos. Através dela percebe-se um super dimensionamento da classe Ocupação Urbana de Baixa Intensidade, e uma diminuição da Ocupação Urbana de Alta Intensidade.

Tabela 2. Áreas (Km<sup>2</sup>) por classe de mapeamento (2000 e 2010) e % de mudança em relação à 2000

Classes	Área (km <sup>2</sup> ) 2000	Área (km <sup>2</sup> ) 2010	2000-2010 (%)
Solo Exposto	4,89	22,72	363,91
Ocupação Urbana Alta Intensidade	379,96	181,61	-52,2
Ocupação Urbana Média Intensidade	14,88	52,30	251,44
Ocupação Urbana Baixa Intensidade	4,79	179,39	3640,35
Vegetação	461,95	432,48	6,38
Água	19,99	17,73	-11,32

Essas inconsistências foram observadas inicialmente de forma visual, e foram confirmadas com os cálculos das áreas. O aumento exacerbado da Ocupação Urbana de Baixa Intensidade (3640,35%) se deve ao fato de sua baixa ocorrência em 2000, e a diminuição da Ocupação Urbana de Alta Intensidade (-52), se deve à alta ocorrência dessa classe em 2000.

#### 4. Conclusões

Diante, portanto, dos resultados apresentados, o modelo classificatório para 2010 se apresentou razoável, atingindo 66,11% de exatidão global, visto que não foi realizada nenhuma edição manual, a fim de refinar o mapeamento, porém, quando é aplicado de forma totalmente automática na data pretérita de 2000 o resultado não se mostra satisfatório, sendo reconhecida, portanto, a necessidade de novos ajustes. Além disso, ainda se indica que a modelagem seja feita por data e área específica, o que faz com que o processo de mineração de dados seja ainda mais relevante para otimizar o mapeamento final, necessitando-se assim de uma árvore de decisão para cada data ou área.

#### 5. Referências Bibliográficas

Novo, Evelyn M. L. de Moraes. **Sensoriamento Remoto: princípios e aplicações**. 4 ed. São Paulo: Blucher, 2010.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Censos Demográficos 1991, 2000, 2010**.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Manual Técnico de Uso da Terra**. 2ª edição. 2006. 91pg

Instituto Pereira Passos (IPP). **PORTALGEO e Armazém de Dados**. Acesso em 12 de janeiro de 2012.

Nascimento, J. P. R.; Madeira, H. M. F.; Hélio, P. **Classificação de Imagens utilizando descritores estatísticos de textura**. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 2099-2106. CD-ROM, On-line. Disponível em [http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2002/11.14.15.15/doc/15\\_185.pdf](http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2002/11.14.15.15/doc/15_185.pdf).

Francisco, C. N.; Almeida, C. M. **Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto**. In: Bol. Ciênc. Geod., sec. Artigos, Curitiba, v. 18, nº2, p.302-326, abr-jun, 2012.