

Classificação Orientada a Objetos na Geração do Mapa de Uso e Cobertura da Terra do estado do Rio de Janeiro

Carla Bernadete Madureira Cruz ¹
Luana Santos do Rosário ¹
Marcelo Bueno de Abreu ¹
Paula Maria Moura de Almeida ¹
Raúl Sánchez Vicens ²
Felipe Mendes Cronemberger ²

¹ Universidade Federal do Rio de Janeiro - UFRJ
Departamento de Geografia – Av. Athos da Silveira Ramos, 283, sala I-012
Cidade Universitária, Ilha do Fundão, Rio de Janeiro, Brasil
{carlamad, almeida.pmm}@gmail.com; luanasantosdorosario@hotmail.com;
buenodeabreu@yahoo.com.br

² Universidade Federal Fluminense - UFF
Departamento de Geografia - Instituto de Geociencias, Campus da Praia Vermelha, Boa
Viagem, Niterói, Rio de Janeiro, Brasil
rcuba@vm.uff.br; felipecron@yahoo.com.br

Abstract. The present work aims to analyze the classification resulting from object-based method, in the construction of a land use map of the Rio de Janeiro state, in the scale 1:100.000. The study required 7 images of Landsat TM sensor, all obtained in August 2007. Two products were compared: an automatically generated map and an edited one. The automatic product was generated using a fuzzy model based on the spectral analysis of the earth features behavior, and the edited one was obtained in a continuous process, where some manual editions were made based on survey information. A top-down approach was used in the classification process. The classes at the same hierarchical level were analyzed and characterized by different object features (descriptors), part of which were personalized through a construction mode available by Definiens Developer software. The results of the whole classification, using the automatic process, became very good, mainly for forestry and pasture classes, which together are responsible for almost 80% of the study area. This work is the result of a big project which main objective is to define special ecological and economical zones for the Rio de Janeiro state. The project is sponsored by the Secretary of the Environment – SMA-RJ.

Palavras-chave: remote sensing, image processing, fuzzy modelling, sensoriamento remoto, processamento de imagens, modelagem fuzzy.

1. Introdução

A geração de produtos temáticos a partir do processamento de imagens ainda embute, apesar de décadas de pesquisa e desenvolvimento, um grande desafio no que concerne ao grau de automatização do processo. Aprimorar a classificação de imagens objetivando a elaboração de mapas temáticos para os mais variados fins tem sido, portanto, alvo de muitos esforços.

Por outro lado, mapear o uso e cobertura da terra também envolve certa complexidade, tanto em termos da diversidade de classes, quanto em relação aos variados níveis de detalhamento que se pode alcançar. Apesar de se constituir em um dos mapas temáticos mais adotados, presente em variadas aplicações, não se tem padronização de legenda que auxilie na caracterização do uso e da cobertura da terra, em diferentes níveis de escala. Com certeza, a amplitude de especializações por parte dos profissionais que podem se encontrar envolvidos na sua geração é um fator que contribui para esta falta de consenso.

Se considerarmos ainda que a geração de mapas de uso e cobertura da terra depende da adoção de produtos de sensoriamento remoto, aéreos ou orbitais, de alta, média ou baixa resolução, o uso de técnicas classificatórias e a efetuação de levantamentos de campo se constituem em etapas essenciais no processo de sua elaboração.

Ainda hoje a maioria das técnicas classificatórias demanda grande esforço de edição manual. Esta realidade divide a comunidade quanto às vantagens da adoção de técnicas automatizadas, a ponto de muitos estudos estarem atrelados somente a interpretações visuais, mesmo que seja cada vez mais comum o uso de segmentações antes da classificação em si.

O objetivo do presente trabalho consiste na avaliação do método de classificação orientada a objetos na geração do mapa de uso e cobertura da terra, em meso escala de detalhamento (1:100.000), para o estado do Rio de Janeiro, no âmbito do Zoneamento Ecológico-Econômico do estado. Especificamente são comparados dois produtos gerados através do processamento de imagens Landsat 5 de agosto de 2007: o primeiro, obtido exclusivamente pelo uso de modelos fuzzy e/ou booleanos numa abordagem orientada a objetos e; o segundo, continuado a partir deste primeiro, finalizado por edição manual apoiada por trabalhos de campo e outras fontes. Esta comparação possibilitará a avaliação do nível de acerto que o processo automatizado alcançou por classe mapeada, dando assim subsídios para novos investimentos em termos metodológicos. Esta técnica apresenta um caráter inovador para as classificações de imagens de sensoriamento remoto, principalmente em produtos de meso escala de detalhamento.

Embora existam muitas experiências em análise orientada a objetos, a maioria delas tem sido realizada com imagens de alta resolução, a maior parte em aplicações urbanas (De Pinho *et. al.*, 2005) e outras recentes voltadas para levantamentos florestais (Carleer & Wolff, 2006). Em escalas regionais são encontradas algumas experiências utilizando imagens de baixa resolução ou média resolução (Fisette *et. al.*, 2006). No presente trabalho buscou-se a adaptação desta metodologia, já testada no mapeamento da cobertura vegetal do bioma Mata Atlântica (Cruz et al, 2007) gerado a partir de imagens ETM Landsat para a escala 1:250.000.

2. Área de Estudo

O estado do Rio de Janeiro, localizado na região sudeste do Brasil, possui área aproximada de 43.750km². Inserido totalmente no bioma Mata Atlântica, apresenta ainda importantes remanescentes de floresta e um dos principais corredores de biodiversidade deste bioma, protegido, em parte, por um mosaico de unidades de conservação e por um relevo acidentado.

O uso predominante em seu território constitui-se de pastagens, ocupação urbana e alguns tipos de agricultura, cuja ocorrência, na maioria das vezes assume caráter regional.

Para abranger todo o estado do Rio de Janeiro foram usadas 7 cenas do satélite Landsat 5 (TM), datadas de agosto de 2007, cuja resolução espacial atende à escala 1:100.000. O fato das imagens terem sido obtidas em menos de um mês é uma vantagem rara que facilita a equalização entre cenas, minimizando diferenças entre datas que podem ser bastante significativas (figura 1).

3. Metodologia

O interesse em se ampliar a eficiência de métodos de classificação automatizada não é recente, embora os avanços neste sentido sejam ainda pouco expressivos. Simular todas as considerações que são efetuadas durante o processo de tomada de decisão em uma interpretação visual não é, de forma alguma, uma tarefa simples. Muitos elementos são avaliados, comparados, ponderados.

A classificação orientada a objetos busca simular técnicas de interpretação visual através da modelagem do conhecimento para a identificação de feições, baseada na descrição de padrões identificadores, tais como, cor, textura, métrica, contexto. O sistema possibilita o uso convencional da técnica vizinho mais próximo a partir da assinatura espectral de alvos (definida por amostras) além da aplicação de modelos booleanos e/ou fuzzy, que podem ser livremente traçados em um ambiente interativo (Cruz et al, 2007).



Cena (TM)	Data
216/074	27/08/2007
216/075	27/08/2007
216/076	27/08/2007
217/075	02/08/2007
217/076	02/08/2007
218/075	25/08/2007
218/076	25/08/2007

Figura 1: Articulação de cenas Landsat para o estado do Rio de Janeiro com datas utilizadas.

Outro fator de extrema relevância é o ajuste geométrico das imagens, de forma a garantir precisão compatível com a escala desejada e a harmonia do mosaico gerado. Para o georreferenciamento das cenas foram levantados pontos de controle em campo e aplicada a técnica de ajuste polinomial, de segunda ordem, com tolerância de 100m (em atendimento ao PEC C para a escala 1:100.000). O erro máximo obtido para as 7 cenas foi de 60m (testado por caminhamentos obtidos em campo, pontos de teste e bases existentes). Os pontos de controle foram obtidos com GPS de navegação através da aquisição por média de observações.

Como cada faixa de imageamento (216, 217 e 218) foi obtida numa mesma data, não foi necessário efetuar a equalização entre cenas de uma mesma faixa, gerando-se simplesmente cada um dos 3 mosaicos de forma direta. Desta forma, cada faixa pôde dar origem a um projeto de classificação específico.

Para a geração do mosaico final (efetuado por banda) para todo o estado do Rio de Janeiro, utilizou-se o sistema Orthoengine, software canadense da PCI.

A classificação se inicia com a delimitação dos objetos através do processo de segmentação. O sistema adotado, o Definiens Developer, possibilita o uso de imagens de diferentes resoluções no projeto, além da geração de vários níveis de segmentação, articulados de forma hierárquica. Na classificação do uso e cobertura da terra para o estado do Rio de Janeiro foram adotados dois níveis de segmentação numa abordagem top-down (que vai do macro para o micro). Para o primeiro nível (acima) foram usadas apenas as bandas do infravermelho 4 e 5 do Landsat, com parâmetro de escala 10 e peso máximo para a cor, em detrimento da forma. Este nível objetivou a separação de corpos d'água, sombras densas e nuvens, das demais classes, denominada Outros. O segundo nível foi gerado com as 6 bandas espectrais do sensor (excetuando a termal), com os mesmos parâmetros do nível anterior. Neste nível buscou-se o detalhamento das demais classes através do estabelecimento de uma legenda hierárquica. A adoção da abordagem top-down garante que os objetos gerados abaixo de um determinado nível respeitem os limites do nível superior, subdividindo objetos ou simplesmente fazendo-os coincidirem com as unidades superiores, jamais agrupando.

A modelagem das classes foi embasada em amostras coletadas em campo, que permitiram a seleção dos melhores descritores (variáveis), obtidos através das bandas espectrais, do modelo digital de elevação do SRTM e do mapa geomorfológico do estado. Utilizou-se, majoritariamente, modelagem fuzzy sobre os descritores. Para cada modelo foram definidos limites de ocorrência que auxiliam na separação de classes, considerando-se certezas e incertezas. A administração da classificação em níveis auxilia na minimização de confusões.

As amostras foram coletadas a partir de caminhamentos efetuados em trabalhos de campo, definidos através dos critérios de acessibilidade e diversidade de ambientes. Foram obtidos aproximadamente 1.500 pontos de observação. A análise e seleção dos descritores mais significativos são apoiadas na visualização de histogramas que comparam duas classes por vez em um ambiente que possibilita a construção dos modelos de forma automática ou manual. Cada classe é então definida por um ou mais modelos, podendo-se ter classes (normalmente a de maior ocorrência) cujo modelo é por exclusão (not demais classes), e assim se evitar áreas não classificadas. É garantida a herança entre níveis de classificação e de objetos, evitando redundâncias e simplificando o processo de identificação. Por exemplo: floresta e reflorestamento podem ser classes pertencentes a uma classe mais genérica, denominada Áreas Florestadas, e herdarem os modelos que caracterizam a classe mãe além dos que as diferenciam entre si.

Neste trabalho são definidos dois produtos diferenciados: o primeiro é o gerado somente pelo processo automatizado da modelagem do conhecimento; o segundo, partindo-se deste, é alcançado após as edições manuais consideradas necessárias para garantir a verdade terrestre.

O processo de edição do mapeamento foi efetuado em duas etapas: uma primeira passagem utilizando o próprio sistema Definiens, pelas vantagens que oferece para a correção em nível pontual; e uma etapa final, no ArcGIS, pelos acertos que sejam valorizados por modificações em nível de banco de dados.

Os dois produtos passaram ainda por um processo de generalização final no sistema ERDAS, de modo a garantir uma melhor representação dos objetos em um mapa temático, eliminando ruídos, suavizando contornos e garantindo a determinação do melhor detalhe para a escala, considerado no caso uma área mínima de 5ha (escala 1:100.000). Os processos adotados foram: 1) aplicação de um filtro de moda com matriz 5x5 (Focal Majority); 2) uma regionalização através da função Cluster; 3) e a eliminação de áreas inferiores a 5ha (Eliminate). Para que corpos d'água pequenos ou muito estreitos não fossem perdidos, recuperou-se esta classe dos arquivos originais (antes da generalização) superpondo-a aos produtos finais.

Os dois produtos foram então mosaicados em um único arquivo cada, com a diferença de que para o editado garantiu-se ainda a ligação entre as partes provenientes de diferentes projetos através de uma nova edição. No ArcGIS, efetuou-se então o cruzamento entre os dois mapas (opção Combine que possibilita a tabulação cruzada entre arquivos matriciais, convertidos no caso com resolução de 30m) e a análise estatística das diferenças e consistências obtidas.

4. Resultados e Discussão

A hierarquia de classes adotada no segundo nível de segmentação foi definida pela seguinte estrutura básica, a partir da qual as classes de legenda foram distribuídas. Os níveis são relacionados através da indicação (ou apontamento) de super objetos.

- Água (nível 1)
- Sombras (nível 1)
- Nuvens (nível 1)
- Outros (nível 1)
 - Áreas Rosas (nível 2)
 - Áreas Verdes (nível 2)
 - Áreas Florestadas (nível 2)
 - Áreas Não Florestadas (nível 2)

A classe “Áreas Verdes” compreendeu as áreas com predomínio da vegetação arbustiva ou florestada, ou ainda pela pastagem em várzea e alguns tipos de cultivos. A classe “Áreas Rosas” correspondeu às áreas sem predomínio da vegetação, como a ocupação urbana, solo

exposto, áreas preparadas para cultivo e a pastagem em geral, aonde o solo contribui muito na mistura espectral, principalmente em imagens do período seco, como é o caso.

A tabela 1 apresenta a porcentagem de acertos entre a classificação automática (não editado) e o produto editado para a separação em áreas verdes e rosas (considerando todas as classes agrupadas nestes níveis). Pode-se perceber que o grau de automatização é alto, dado que para as duas macro-classes obteve-se um percentual superior a 80%.

Tabela 1: Grau de automatização do nível superior da hierarquia de classes

Editado	Não Editado	
	Verde	Rosa
Verde	80,87%	18,93%
Rosa	6,58%	93,13%

A análise do grau de automatização entre os sub-níveis da classe “Áreas Verdes” (Áreas Florestadas – que agrupa as classes “Floresta”, “Mangue”, “Mata de Restinga” e “Reflorestamento” e Áreas Não Florestadas – que agrupa as classes com predomínio de gramíneas) é apresentada na tabela 2, que indica um maior acerto para as áreas florestadas (94%). Os descritores adotados para a caracterização das áreas florestadas para os 3 projetos criados (por faixa de imageamento) ainda variam muito, mas se mantêm em torno das médias obtidas para as bandas do visível e infravermelho médio (banda 5).

Tabela 2: Grau de automatização das áreas florestadas e descritores utilizados

Editado	Não editado		Descritores da faixa 216	Médias das bandas 3 e 5 e máxima diferença
	Florestado	Não florestado		
Florestado	94%	5,51%	Descritores da faixa 217	Média das bandas do visível e das bandas 5 e 7
Não florestado	44%	56,12%	Descritores da faixa 218	Média das bandas do visível

A tabela 3 sintetiza a distribuição das classes de uso e cobertura da terra para os dois produtos gerados (editado e não editado). Sua leitura mostra que os resultados obtidos de forma automática se aproximam muito dos editados, o que resulta em valores baixos na coluna Diferença, na qual os esforços de inclusão (positivos) ou exclusão (negativos) de objetos por classe são apresentados. Ressalta-se aqui que a classe agricultura foi modelada como uma classe única e editada com a diferenciação entre Cana, Café, Cítricos e Outros, o que resultou em erros de automatização, apesar de se tratar, de fato, de uma carência da modelagem do conhecimento para este fim.

Tabela 3: Valores percentuais do uso e cobertura da terra

Uso e Cobertura da Terra	Editado (%)	Não Editado (%)	Diferença (%)
Afloramento Rochoso	0,49	0,18	0,31
Agricultura (outros)	0,47	0,75	-0,28
Agricultura (café)	0,12	0,00	0,12
Agricultura (cana)	3,99	0,00	3,99
Agricultura (cítricos-coco)	0,05	0,00	0,05
Comunidade Relíquia	0,07	0,03	0,04
Cordões Arenosos	1,32	0,13	1,19
Dunas	0,02	0,04	-0,02
Floresta	27,92	30,71	-2,79
Mangue	0,47	0,55	-0,08

Ocupação Urbana de Alta Densidade	1,34	1,40	-0,06
Ocupação Urbana de Baixa Densidade	1,16	0,29	0,87
Ocupação Urbana de Média Densidade	2,57	1,49	1,08
Pastagem	51,35	58,69	-7,35
Pastagem em Várzea	2,74	1,34	1,40
Reflorestamento	0,26	0,16	0,10
Restinga	0,84	0,49	0,35
Salinas	0,08	0,00	0,08
Solo exposto	0,10	0,00	0,10
Vegetação Secundária em Estágio Inicial	2,00	1,25	0,75
Água	1,99	1,79	0,20
Áreas Úmidas	0,64	0,43	0,22
Sombra	0,00	0,27	-0,27
TOTAL	100,00	100,00	





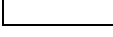
Propondo uma classificação para o grau de automatização do processo de modo a facilitar a análise da performance obtida e a definição de classes de maior necessidade de investimento na modelagem, a tabela 4 apresenta os percentuais de acerto por classe de uso e cobertura da terra, classificados em Alto, Bom, Regular e Baixo grau de automatização.

Tabela 4: Acerto na classificação e níveis de automatização

Classes de Uso e Cobertura da Terra

Água	84,07%
Áreas Úmidas	24,35%
Afloramento Rochoso	16,71%
Agricultura	14,78%
Agricultura (café)	
Agricultura (cana)	
Agricultura (citricos-coco)	
Comunidade relíquia	14,39%
Cordões Arenosos	7,80%
Dunas	20,17%
Floresta	92,81%
Mangue	73,90%
Ocupação Urbana de Alta Densidade	78,04%
Ocupação Urbana de Média Densidade	40,46%
Ocupação Urbana de Baixa Densidade	1,38%
Pastagem	92,45%
Pastagem em Várzea	28,57%
Reflorestamento	10,82%
Restinga	36,94%
Salinas	
Solo exposto	0,00%
Vegetação Secundária em Estágio Inicial	33,15%

Grau de Automatização

	100-75% (Alto)
	75 a 50% (Bom)
	50 a 25% (Regular)
	25 a 0% (Baixo)
	Não modelados

As classes de menor acerto (em rosa), que necessitam de maiores investimentos em modelagem, justificam seus resultados no âmbito do presente mapeamento, por:

- Agricultura (todos os tipos): a modelagem não investiu na diferenciação dos tipos de cultivo. Se a análise fosse feita sem a sub-divisão em 4 classes de cultivo o grau de acerto seria em torno de 34%.
- Afloramento rochoso, Salinas, Dunas e Comunidade relíquia: não tiveram grande investimento na modelagem por terem baixa expressão espacial no estado (menos de

1%) e se apresentarem de forma concentrada ou pontual, o que facilita a classificação visual.

- Cordões arenosos, Solo exposto e Ocupação urbana de baixa densidade: apresentaram grande confusão com a classe pastagem (mais de 80% para cordões arenosos, 70% para solo exposto e 60% para ocupação de baixa densidade), o que se justifica pela alta mistura que estas classes apresentam com o solo e as gramíneas.
- Áreas úmidas: seria interessante se ter imagens do período úmido também para que os modelos fossem aprimorados, considerando diferenciações sazonais.
- Reflorestamento por Eucalipto: apresentou grande confusão com a classe floresta com quem tem alta correlação espectral.

Complementando a análise dos erros, elaborou-se ainda um mapa com a distribuição espacial das confusões. A figura 2 apresenta em cinza tudo o que foi mapeado de modo automático e em vermelho os esforços em edição manual. O recorte destacado na porção leste do estado representa extensas áreas de cana e cordões arenosos. As áreas de cana são definidas por um mosaico de diversas tonalidades, dependentes de ações de queimada, colheita e diferentes estágios de desenvolvimento.

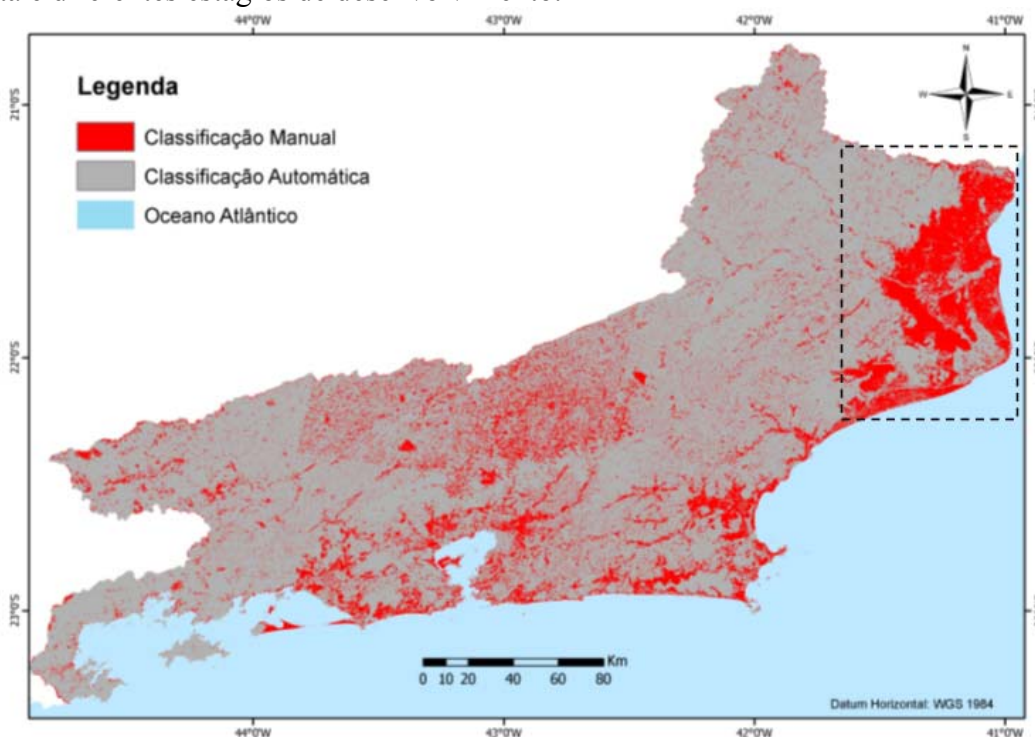


Figura 2: Mapa de distribuição dos esforços de edição manual

Este mapeamento possibilitou a configuração de um painel atualizado, de extrema relevância para o planejamento e a gestão do território, de caráter inédito para o estado do Rio de Janeiro. Numa caracterização rápida, através da leitura dos dados anteriores e do mapa final apresentado na figura 2, verifica-se que o Rio de Janeiro apresenta um uso e cobertura da terra bastante homogêneo, com poucas classes de predominância, como é o caso da pastagem e da floresta, que juntas respondem por quase 80% do território. Apesar de apresentar distribuição diferenciada para as regiões de estado, esta uniformidade é facilmente percebida através da concentração de florestas nas áreas de relevo mais acidentado, formando o corredor da Serra do Mar, e de um mosaico de pequenos fragmentos inseridos em uma matriz de pastagem.

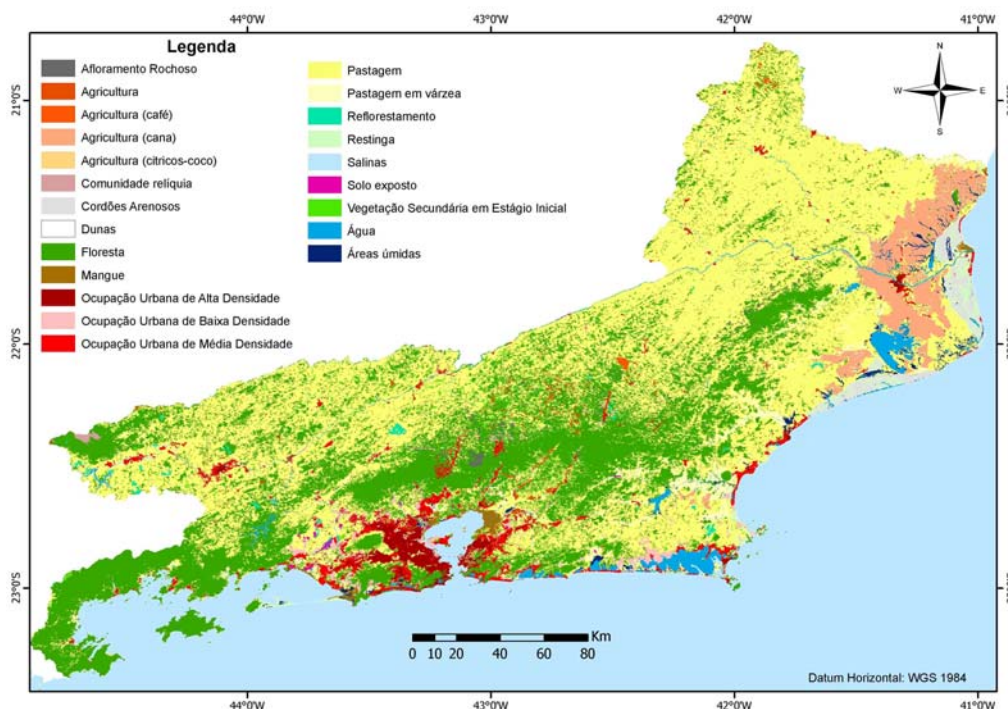


Figura 2: Mapa de Uso e Cobertura da Terra do estado do Rio de Janeiro

5. Conclusões

A experiência de classificação através da modelagem do conhecimento, iniciada pelo nosso grupo em 2005, tem apresentado importantes avanços, estimulando maiores investimentos de pesquisa. Para o presente estudo, em um esforço de mapeamento de uma área de aproximadamente 45.000 km², com áreas de relevo bastante movimentado, com sombreamentos que geram complexidade na identificação de classes, não há dúvidas quanto aos ganhos em relação à redução do tempo de execução (10 meses para todo o processo) e, conseqüentemente, de custos.

Investigações vêm sendo realizadas de forma a consolidar os modelos adotados. A possibilidade de se trabalhar as classes de forma individualizada e de se exportar modelos para outros projetos são fatores diferenciadores na metodologia. Para a versão atual do software Definiens Developer tem-se ainda a possibilidade da criação e exportação da árvore de processos, o que facilitaria a produção de dados, mantendo a necessidade de poucos esforços de ajustes.

Referências Bibliográficas

- CARLEER, A.P. and WOLFF E. (2006): **Region-based classification potential for land-cover classification with very high spatial resolution satellite data**. In: Proceedings of the 1st International Conference on Object-based Image Analysis, Salzburg University, Austria.
- CRUZ, C.B.M., VICENS, R.S., SEABRA, V.S., REIS, R.B., FABER, O.A., RICHTER, M., ARNAUT, P.K.E., ARAUJO, M. (2007) **Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000**. XIII Simpósio Brasileiro de Sensoriamento Remoto, INPE, Florianópolis, Brasil.
- DE PINHO, C. M., FEITOSA, F. and H. J. KUX (2005): **Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre a abordagem pixel-a-pixel e orientada a objetos**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, INPE, Goiânia, Brasil.
- FISSETTE, T., CHENIER, R., MALOLEY, M., GASSER, PY., HUFFMAN, T., WHITE, L., OGSTON, R. and ELGARAWANY, A.(2006): **Methodology for a Canadian agricultural land cover classification**. In: Proceedings of the 1st International Conference on Object-based Image Analysis, Salzburg University, Austria.