

Revista Brasileira de Cartografia (2014) N^o 66/5: 993-1005
Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto
ISSN: 1808-0936

CLASSIFICAÇÃO ORIENTADA A OBJETOS PARA MAPEAR FLORESTAS SECUNDÁRIAS EM SANTA CATARINA, SUL DO BRASIL

*Object-based Classification for Mapping Secondary Forests in Santa Catarina,
Southern Brazil*

Gustavo Antonio Piazza¹ & Alexander Christian Vibrans²

¹Fundação Universidade Regional de Blumenau - FURB
Programa de Pós-Graduação em Engenharia Ambiental
Bloco I (sala I-100), Rua São Paulo, 3250, 89.030-000, Blumenau, SC
gustavoapiazza@gmail.com

²Fundação Universidade Regional de Blumenau - FURB
Programa de Pós-Graduação em Engenharia Ambiental
Inventário Florístico Florestal de Santa Catarina - IFFSC
Rua São Paulo, 3250, 89.030-000, Blumenau, SC
acv@furb.br

Recebido em 28 de Novembro, 2013/ Aceito em 10 Abril, 2014
Received on November 28, 2013/ Accepted on April 10, 2014

RESUMO

A Mata Atlântica é um dos biomas brasileiros mais ameaçados. Grande parte de seus remanescentes é representada por fragmentos florestais secundários, formando uma paisagem repleta de mosaicos de estágios sucessionais e de outros usos do solo. Técnicas de sensoriamento remoto são essenciais para o seu mapeamento e monitoramento. Entretanto, com o advento de sensores com maior resolução espacial e espectral, novas técnicas de processamento e análise dos dados captados foram criadas, pois ferramentas tradicionais, como a classificação pixel-a-pixel, mostraram-se insuficientes. Este estudo teve por objetivo utilizar uma destas novas ferramentas, a classificação orientada a objetos, em fotografias aéreas de alta resolução espacial (0,39 x 0,39 m) com três bandas no espectro visível (0,38 - 0,70 μm) para mapear os estágios iniciais de regeneração de florestas secundárias da Floresta Ombrófila Densa em Santa Catarina, Brasil. Baseado em escala, forma e compacidade, foi utilizado o algoritmo de segmentação multiresolução para gerar objetos e determinar seus atributos espectrais, espaciais e texturais. Para a classificação foram utilizados oito atributos selecionados, entre espectrais e espaciais. A acuracidade geral da classificação obteve índice Kappa de 0,84, variando de 1,00 (floresta em estágio avançado), 0,95 (área agrícola), 0,66 (floresta em estágio inicial) a 0,58 (floresta plantada). Estas últimas duas classes apresentaram heterogeneidade espectral maior, pela sua variabilidade natural (estágio inicial) e por serem reflorestamentos não empresariais com deficiências silviculturais, influenciando o desempenho da técnica utilizada.

Palavras chaves: Sensoriamento Remoto, Segmentação Multiresolução, Atributos, Sucessão Florestal.

ABSTRACT

The Atlantic Forest is one of the most threatened Brazilian biomes. Most of its remnants are secondary forests, which compose a landscape mosaic of successional stages and other land uses. Remote sensing techniques are important for mapping and monitoring of its forest cover. However, new sensors with major spatial and spectral resolution, demanded

new processing and analysis procedures, since traditional tools like pixel-to-pixel-classification become insufficient. This study aimed to use one of these new techniques, the object-oriented classification for mapping secondary formations of Dense Ombrophilous Forests in Santa Catarina, Southern Brazil with high resolution aerial photography (0.39 x 0.39 m) with three visible bands (0.38 to 0.70 μm). Based on scale, shape and compactness, multiresolution segmentation algorithm was used to create objects and to calculate its spatial, spectral and texture attributes. For classification were used seven spectral and one spatial attributes. The overall classification accuracy achieved Kappa 0.84. The object-oriented analysis proved to be satisfactory to classify the classes forest in advanced stage (Kappa 1), pasture/agriculture (0.95), initial stage forest (0.66) and planted forest (0.58). These two classes showed large heterogeneity due to natural processes (early stage forests) and low quality and high mortality in smallholder forest plantations, decreasing mapping accuracy performance.

Keywords: Remote Sensing, Multiresolution Segmentation, Attributes, Forest Succession.

1. INTRODUÇÃO

Ecossistemas florestais apresentam elevada riqueza biológica e diversidade genética (HOLDRIDGE, 1967; DINERSTEIN et al., 1995; WHITMORE, BURSLEM, 1998). Sua estrutura e composição são resultantes da interação, ao longo do tempo, de fatores abióticos, bióticos e antrópicos. O fator antrópico, entretanto, há muito tempo prevalece sobre o natural, fazendo com que a cobertura florestal em várias partes do globo não seja mais contínua, constituindo-se de uma espécie de mosaico, composto por relictos de florestas em diferentes estágios de sucessão e de degradação florestal (LIEBSCH et al., 2008). As principais pressões antrópicas sobre as florestas naturais se dão a partir do avanço da fronteira agrícola, da industrialização e da urbanização (DEAN, 1997).

De forma geral, todos os biomas florestais sofreram e continuam a sofrer pressões antrópicas, no entanto, nas últimas décadas, as florestas tropicais vêm sendo reduzidas devido à proximidade de regiões com alta taxa de crescimento demográfico e expansão econômica. Segundo Ribeiro et al. (2009), restam de 11 e 16% da área de domínio da Mata Atlântica no Brasil (RIBEIRO et al., 2009). O cenário catarinense é um pouco mais favorável, com 28% do território coberto pela Mata Atlântica (VIBRANS et al., 2013), embora grande parte destes remanescentes seja constituída por fragmentos de formações florestais secundárias (SCHUCH, 2008); poucos núcleos ainda são classificados como florestas maduras, ditas “primárias”. Devido à diminuição destas áreas cobertas por florestas primárias, há um crescente interesse no estudo das florestas secundárias (BORMANN; LIKENS, 1979; OLIVER, 1981; DUBOIS, 1990; LUGO, 1997; CHOKKALINGAN; DE JONG, 2001;

SIMINSKI et al., 2013), para entender processos dinâmicos, como regeneração e recuperação, com implicações para sua conservação e manejo.

Para compreender os processos dinâmicos das florestas é necessária a análise de suas mudanças florísticas e estruturais em diversas escalas espaciais e temporais (TEIXEIRA et al., 2009; LIEBSCH, 2008), mediante levantamento terrestres e de sensoriamento remoto. O sensoriamento remoto tornou-se, nas últimas décadas, com os avanços tecnológicos e o aumento da resolução espacial, espectral e radiométrica dos dados, uma importante ferramenta para a análise e a classificação da cobertura florestal, assim como para o monitoramento de mudanças (JENSEN, 2005) e a obtenção de informações acuradas de objetos terrestres (CLARK et al., 2010). Segundo Prado et al. (2010) utilizar dados orbitais de sensoriamento remoto é uma forma eficiente para o monitoramento e estudo da superfície terrestre, auxiliando na identificação do modelo de organização e na quantificação de áreas desflorestadas e processos de regeneração florestal.

Inicialmente, técnicas de processamento digital de dados de sensoriamento remoto e de classificação foram utilizadas para mapear áreas desmatadas (TUCKER; TOWNSHEND, 2000), enquanto que a identificação da regeneração, como florestas secundárias, não foi alvo principal das análises (VIBRANS et al., 2013). Este foco inicial ocorreu porque naquela época o objetivo inicial era suprir a demanda por informações do desmatamento. Havia naquela época uma barreira tecnológica, pois o uso de métodos tradicionais de processamento encontrou limitações por fatores, como a resolução espacial, espectral e o tamanho das áreas a serem mapeadas, que

não eram adequadas para reconhecimento de formações florestais secundárias. Segundo Centeno et al. (2003), até recentemente, os dados colhidos por sistemas de sensoriamento remoto a bordo de satélites se encontravam limitados no estudo do ambiente urbano devido a sua baixa resolução espacial, porém recentemente, tais limitações foram superadas e imagens com resolução espacial em torno de um metro são mais facilmente adquiridas.

Apesar da melhoria da qualidade das imagens dos sensores remotos e das ferramentas de análise digital, observa-se que estudos para a classificação de florestas secundárias ainda são incipientes e restritos a ferramentas tradicionais e com imagens de média resolução espacial (TEIXEIRA et al., 2009). Por consequência, as estimativas de mapeamentos da cobertura florestal e do uso e ocupação do solo realizados em Santa Catarina entre os anos de 2005 e 2010 apresentaram resultados muito discrepantes em relação à área florestada, com valores entre 22% e 41% (VIBRANS et al., 2013).

A origem desta discrepância pode ser relacionada, a diversos fatores: (i) à falta de critérios consistentes de definição de “floresta”, tanto sob perspectivas sensóricas bem como florísticas, como por exemplo, área mínima, altura e área basal da vegetação; (ii) à própria dificuldade de classificar a vegetação nos estágios iniciais de sucessão, devido às deficiências na caracterização espectral em imagens de média resolução espacial; (iii) à metodologia utilizada para a classificação. De acordo com Vibrans (2003), a cobertura florestal de Santa Catarina não é homogênea nem contínua (composta de florestas e remanescentes alterados) e a separabilidade espectral das comunidades vegetais nem sempre é notável, principalmente em imagens de média resolução. Por isso, no sentido de reduzir a ocorrência desta discrepância, este trabalho propõe uma metodologia que diminui a possibilidade do erro em relação à abordagem metodológica e a deficiência espectral. Tendo em vista que, áreas de remanescentes na Mata Atlântica, geralmente, ocorrem em pequenas manchas entremeadas por cultivos agrícolas ou pastagens, tornando a classificação destes mosaicos de vegetação e outros usos um grande desafio (CASTILHO et al., 2012).

1.1 Florestas secundárias

Florestas secundárias são unidades vegetais em regeneração, que sofreram alguma perturbação antrópica e/ou natural em um único momento ou durante um período prolongado; elas apresentam diferenças na estrutura e na composição de espécies, em relação a florestas maduras próximas (CHOKKALINGAM; JONG, 2001). Estas formações apresentam também características diferentes em função de sua idade. Na Floresta Ombrófila Densa, elas são divididas em três classes pela Resolução CONAMA nº 4/1994 (BRASIL, 1994): (i) o estágio inicial, predominantemente herbáceo/arbustivo de baixo porte, com poucas espécies arbóreas; este possui altura média das árvores de até 4 metros com cobertura vegetal variando de fechada a aberta (sem sub-bosque) e diâmetro à altura do peito (DAP) médio inferior a 8 centímetros; (ii) o estágio médio tem uma fisionomia arbórea e arbustiva, com a altura média de até 12 metros (com cobertura aberta a fechada e ocorrência de indivíduos emergentes) e DAP médio de até 15 centímetros; (iii) o estágio avançado, com fisionomia arbórea, com dossel fechado e relativamente uniforme; a altura média total das árvores é superior a 20 metros e o DAP médio é superior a 25 centímetros; florestas nesse estágio podem apresentar fisionomia semelhante à vegetação primária.

De acordo com Vieira et al. (2003), esta classificação da Resolução CONAMA tem sido comumente utilizada por pesquisadores que trabalham na área de sensoriamento remoto, por ser prática e objetiva.

1.2 Evolução das técnicas de sensoriamento remoto

Barrett e Curtis (1992) definem o sensoriamento remoto como o conjunto de técnicas de observação de alvos terrestres, seja ele um objeto, área ou fenômeno, por meio de um instrumento de captação no qual não há contato direto com o objeto de estudo. Utiliza-se a ação conjunta de sensores remotos, que registram as interações da radiação eletromagnética (REM) e equipamentos de processamento de dados geográficos, com objetivo de estudar os elementos da superfície terrestre, extraindo

dos dados de determinada faixa do espectro eletromagnético informações passíveis de interpretação para geração de produtos, como mapas temáticos (NOVO, 1998; MOREIRA, 2005).

Técnicas de sensoriamento remoto vêm sendo aplicadas com eficiência na detecção da extensão e da intensidade dos impactos humanos (MONTEIRO et al., 2007). Estas técnicas podem ser manuais e automáticas. A técnica manual ocorre pela interpretação visual que utiliza o conhecimento humano para detectar e delinear áreas, entretanto, este é um processo lento de extração de informações e limitado pela capacidade de interpretação humana (SOUZA Jr et al., 2003). Já as automáticas vêm evoluindo de acordo com os avanços tecnológicos. As primeiras classificações automáticas de imagens de sensoriamento remoto consideravam apenas os valores de radiância ou reflectância de cada pixel (FRANCISCO; ALMEIDA, 2012; MONTEIRO et al., 2007), por isso, intituladas *pixel-a-pixel*. Sensores de alta resolução, entretanto, impõem barreiras para a extração de informação, principalmente para metodologias tradicionais de classificação (CADENA, 2011). Para Meinel e Neubert (2005), as tradicionais abordagens de classificação (ou *pixel-a-pixel*) tornam-se limitadas para imagens que captam detalhes de cenas muito heterogêneas e com grande variação interna das classes, como imagens de alta resolução. Centeno et al. (2003) explica ainda que para a análise de imagens de alta resolução espacial, sejam obtidas por sensores espaciais ou fotografias aéreas, requer a implementação de novos métodos e entre as opções disponíveis na atualidade se destaca a abordagem orientada a regiões.

Por isso, a fim de diminuir a ocorrência de problemas em relação à heterogeneidade dos objetos estudados, surge no início da década de 1980 um novo paradigma para a análise de imagens; na classificação baseada em regiões, agrupamentos rotulados de *pixels* contíguos (denominados segmentos) passam a ser a unidade básica de classificação (FRANCISCO; ALMEIDA, 2012). Para Definiens (2009), a classificação orientada a objetos parte da premissa que a informação necessária para a interpretação de uma imagem não está presente somente no pixel, mas também nos objetos da

imagem e nas relações entre eles. Com esta nova abordagem para a interpretação de imagens, o objeto é entendido como a instância (ou exemplo) de uma classe e a classe é representada por um conjunto de objetos com características semelhantes. As características de um objeto são denominadas atributos e as funções para manipulá-los ou retratar seu comportamento são chamadas de métodos (FRANCISCO; ALMEIDA, 2012). Uma das grandes vantagens da análise orientada a objetos sobre a *pixel-a-pixel*, é que na abordagem por *pixels* é possível extrair apenas atributos espectrais e na orientada a objetos extraem-se atributos espaciais, texturais e de contexto. De acordo com Pinho (2006), Alves et al. (2007) e Prado et al. (2010), este método é comumente empregado em ambientes urbanos dada a sua grande capacidade de discriminação de objetos, sendo o potencial da classificação orientada a objetos ainda pouco explorado em ambientes agrícolas e florestais.

A classificação orientada a objetos, no entanto, é mais complexa, uma vez que consiste de duas etapas, segmentação e classificação propriamente dita. A segmentação compreende a etapa de divisão de objetos ou regiões homogêneas da imagem, em função de seus atributos, por meio de um determinado algoritmo (GONZÁLEZ; WOODS, 2000).

1.3 Segmentação Multiresolução

Na plataforma do *software* eCognition (DEFINIENS, 2009) encontra-se disponível o algoritmo de segmentação multiresolução (*Multiresolution Segmentation*). Proposto por Baatz e Schäpe (2000), este algoritmo é um dos principais algoritmos de segmentação de imagens de sensoriamento remoto. Ele utiliza a técnica de fusão de regiões emparelhadas (*pairwise*), no qual pares ou regiões de pixels são fundidos em unidades maiores através de interações por meio do algoritmo *Fractal Net Evolution Approach* (FNEA), desde que o limiar superior de homogeneidade não seja excedido (DEFINIENS, 2009). O algoritmo baseia-se em quatro critérios: escala, cor, suavidade e compacidade (Fig. 1). A escala é o parâmetro principal que determina a heterogeneidade máxima contida nos objetos (SILVA, 2012), ou seja, um alto valor gera objetos maiores (menos segmentos) e um valor mais baixo

gera objetos pequenos (vários segmentos). A homogeneidade dos segmentos é construída a partir do conceito de heterogeneidade interna das regiões e é controlada por dois critérios (BAATZ; SCHÄPE, 2000). Esses critérios levam em conta atributos de cor e forma, que são ponderados pelo tamanho dos objetos. A cor é o critério que define a importância do valor espectral durante a segmentação e a forma é representada pelos critérios de suavidade e compacidade. No critério forma, um baixo valor de compacidade (suavidade) atribui mais importância ao contorno dos objetos, enquanto um valor mais elevado (compacidade) atribui prioridade à geometria dos objetos. Francisco e Almeida (2012), neste mesmo sentido, detalham que um alto valor de compacidade produz segmentos menores e compactos, tipicamente relativos a alvos antrópicos, como construções. Por outro lado, um alto valor de suavidade gera segmentos com bordas suaves, ou relativos a alvos naturais (KRESSLER; STEINNOCHER, 2006).

1.4 Classificação

Atualmente, o modelo de classificação de imagens evoluiu para o que se convencionou chamar árvore de processos, que explica toda operação de interpretação de imagens (segmentação, classificação e pós-classificação). Uma das formas de organizar tais informações a serem classificadas é heurísticamente, pelo usuário, após testes iterativos e interativos com descritores e atributos, no sentido de formular funções/algoritmos de discriminação de classes (FRANCISCO; ALMEIDA, 2012).

A vantagem desta metodologia na análise

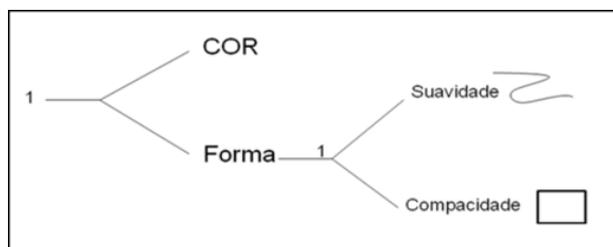


Fig. 1 - Diagrama de execução do algoritmo de segmentação multiresolução. Fonte: Silva (2012).

Onde:

$COR = 1 - Forma$;

$Forma = Compacidade + Suavidade$;

$Suavidade = (1 - \beta compacidade) * Forma$; e

$Compacidade = \beta compacidade * Forma$.

orientada a objetos está no fato de que os objetos representam uma base de dados passível de ser trabalhada (MARPU, 2009), oriunda de valores agrupados de *pixels*, como por exemplo, parâmetros estatísticos (média e desvio padrão de objetos) e outros coeficientes relacionados às suas propriedades (textura e contexto).

1.5 Área de estudo

A área de estudo está situada na divisa dos municípios Indaial e Ascurra, no centro norte de Santa Catarina (Fig. 2). A região faz parte da região fitoecológica da Floresta Ombrófila Densa, de acordo com Klein (1978) e do levantamento do Inventário Florístico Florestal de Santa Catarina (IFFSC) (VIBRANS et al., 2012).

O local de estudo tem 4000 m de comprimento e 2500 m de largura, compreendendo uma área total de aproximadamente 1000 hectares.

2. MATERIAL E MÉTODOS

Inicialmente foi apresentada a origem da base de dados e os materiais utilizados na proposta. Em sequência apresentaram-se os procedimentos utilizados para a extração dos objetos pela segmentação, quais as classes de uso do solo, como foram escolhidos os atributos de diferenciação de classes de uso do solo, e por final foi detalhado o processo de classificação orientado a objetos assim como a metodologia de aferição das informações geradas.

2.1 Base de dados e material utilizado

A imagem utilizada é proveniente do levantamento aéreo executado pela Secretaria de Estado do Desenvolvimento Econômico

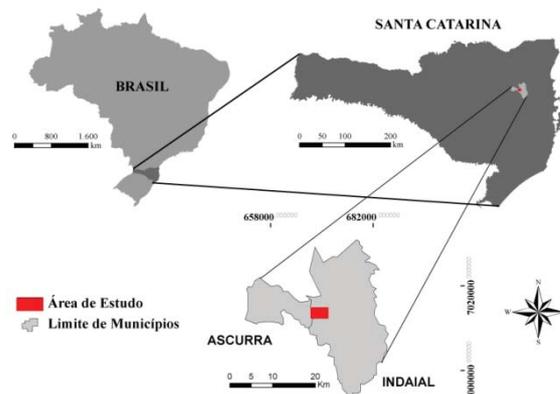


Fig. 2 - Localização da área de estudo

Sustentável (SDS-SC), obtida no ano de 2011. A área de estudo é um recorte de uma ortofotografia aérea, obtida na escala nominal 1:5.000 (PEC/1984), com altura média do voo de 3.985 m e distância focal de 50 mm. O levantamento foi realizado com um Sistema Aerotransportado de Aquisição e Pós-processamento de Imagens Digitais (SAAPI), que possui sensor CCD com tamanho do pixel de 6 microns e um filtro UV-Sky que filtra a luz ultravioleta e compensa o efeito de bruma atmosférica.

O produto utilizado tem três bandas (azul: 0,38 – 0,52 μm ; verde: 0,52 – 0,63 μm ; vermelho: 0,63 -0,70 μm), com resolução espacial de 0,39 m x 0,39 m e resolução radiométrica de 8 bits. Utilizaram-se apenas as bandas do visível, pois o restante do produto (infravermelho, modelo de superfície e modelo de terreno) não foi disponibilizado pela Secretaria, devido a problemas de pré-processamento. O pacote de dados foi entregue com ajuste radiométrico, níveis de contraste e tonalidade, homogeneização das imagens, balanceamento de cores, ortorretificação e mosaicagem (ENGEMAP, 2012).

Para o desenvolvimento da pesquisa foram utilizados os *softwares* eCognition Developer® 8.0 e ArcGIS® 10.1 (extensão ArcMap).

2.2 Extração dos objetos

Para a criação dos objetos foi utilizado o algoritmo de segmentação multiresolução, devido ao seu melhor desempenho no delineamento dos objetos em imagens de alta resolução, disponível na plataforma do *software* eCognition Developer 8.0.

A segmentação multiresolução foi estabelecida a partir da combinação de parâmetros de forma e compacidade dos objetos. No campo forma foram definidos valores de 0 a 1 (mínimo e máximo disponível), que modificam a relação entre os critérios de homogeneidade espacial (1) e informação espectral (0); o mesmo intervalo foi utilizado para o parâmetro compacidade, que modifica critérios de contorno (0 suave e 1 brusco). A alteração dos valores de cada parâmetro, assim como a sinergia entre eles, gerou diferentes cenários de segmentação. Neste estudo, buscou-se obter uma segmentação “adequada” para os estágios sucessionais da

vegetação, ou seja, não tendo muita importância para o tamanho dos objetos, mas priorizando os contornos bruscos (devido à fragmentação). Por isso, testaram-se valores baixos de compacidade e de forma (máximo de 0,5 para ambos), fornecendo assim prioridade à suavidade dos contornos e a cor (informação espectral) dos objetos. Para a escala valores na escala de centenas foram testados (Tabela 1).

2.3 Definição das classes

Antes de iniciar a classificação foi necessário definir as classes a serem utilizadas no mapa temático. As classes seguem o padrão utilizado nos mapeamentos florestais de Santa Catarina (VIBRANS et al., 2013). Utilizaram-se as classes: floresta em estágio inicial, floresta em estágio avançado, plantações florestais (pinus/eucalipto), área agrícola (pastagem/agricultura), solo exposto, área urbana, sombra e lago (Tabela 2). A caracterização das classes foi realizada com base na interpretação visual da imagem e visitas a campo.

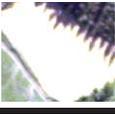
2.3 Atributos de diferenciação

Devido à natureza de cada objeto gerado é possível defini-lo e quantificá-lo de acordo com atributos. Para Batista (2006), um atributo é uma

Tabela 1: Parâmetros utilizados na fase de testes

Forma	Compacidade	Escalas
0,1	0,1	100, 200, 300
0,1	0,3	100, 200, 300
0,1	0,5	100, 200, 300
0,3	0,1	100, 200, 300
0,3	0,3	100, 200, 300
0,3	0,5	100, 200, 300
0,5	0,1	100, 200, 300
0,5	0,3	100, 200, 300
0,5	0,5	100, 200, 300

Tabela 2: Exemplo das classes utilizadas de acordo com a imagem

Classe	Amostra	Classe	Amostra
Floresta estágio inicial		Solo exposto	
Floresta estágio avançado		Área urbana	
Floresta plantada		Sombra	
Área agrícola		Lago	

designação de uma variável categorizada por uma característica cognitiva própria, associada a uma classe ou a um elemento de representação. A escolha dos atributos foi auxiliada pela ferramenta *Feature Space Optimization* do *software* eCognition®, no qual 30 atributos (dentre eles atributos espectrais, espaciais e texturais) foram selecionados, assim como amostras das classes. Desta forma, o *software* indica os atributos com maior separabilidade entre as classes. Dentre os atributos selecionados, foram escolhidos (de acordo com o índice de separabilidade) sete atributos espectrais e um espacial (Tabela 3).

2.4 Classificação orientada a objetos

O método de classificação escolhido foi por funções de pertinência (*logical terms*), no qual algoritmos foram utilizados para assinalar um objeto conforme critérios (por exemplo,

brilho < 50 [até 256] = sombra) levando em conta valores inerentes aquela classe. Foram empregados apenas atributos espectrais e um espacial.

Para a realização da classificação por função de pertinência com o *software* eCognition® foram executadas duas etapas: reconhecimento das características dos objetos e aplicação de lógica da função de pertinência. O propósito da primeira etapa consistiu da análise individual de várias amostras da imagem (escolhidas aleatoriamente), sendo que de cada amostra escolhida fazia-se uma anotação, em uma planilha eletrônica, do valor referente àquela classe, tendo em vista os atributos selecionados (Fig. 3a). Depois de compilados os dados de várias amostras e classes, analisou-se a planilha eletrônica como um todo, definindo valores máximos e mínimos por atributos e por classe. Depois de definidos os valores por classe, utilizaram-se as funções de pertinência (Booleanas e *Fuzzy*). Com a lógica Booleana são estabelecidos critérios rígidos (ex: > 30) e com a *Fuzzy* é possível fornecer intervalos de pertinência (ex: intervalo entre 50 e 30 através de uma função de decaimento) (Fig. 3b).

2.4 Avaliação da classificação

Para avaliar a acurácia do mapa temático, foram coletadas amostras estratificadas das oito classes. Embora o número de amostras preconizado por Congalton e Green (2009) para este tipo de análise seja maior, nesse trabalho, devido à área reduzida de algumas classes, foram coletadas entre 30 e 60 amostras para avaliar a acurácia do mapa temático.

Em sequência foi construída a matriz de erros por meio das estatísticas de estabilidade de classificação fornecidas pelo *software*

Tabela 3: Atributos eleitos pela ferramenta *Feature Space Optimization*

Atributo	Descrição
<i>Brightness</i> (Brilho)	Número digital (ND) de acordo com todas as bandas da imagem;
<i>Mean</i> (Reflectância)	ND médio de acordo com cada banda;
<i>Max Difference</i> (Máxima diferença)	Maior diferença entre os ND em todas as bandas;
<i>Standard Deviation</i> (Desvio padrão)	Desvio padrão do ND de acordo com uma banda;
<i>Ratio</i> (Razão da banda)	ND de uma banda em relação às outras bandas (contribuição de uma banda em relação ao brilho);
<i>Minimum pixel value</i> (Menor valor de um <i>pixel</i>)	Menor valor do ND em relação a uma banda;
<i>Maximum pixel value</i> (Maior valor de um <i>pixel</i>)	Maior valor do ND em relação a uma banda
<i>Area</i> (Área)	Número total de <i>pixels</i> contidos dentro de um objeto

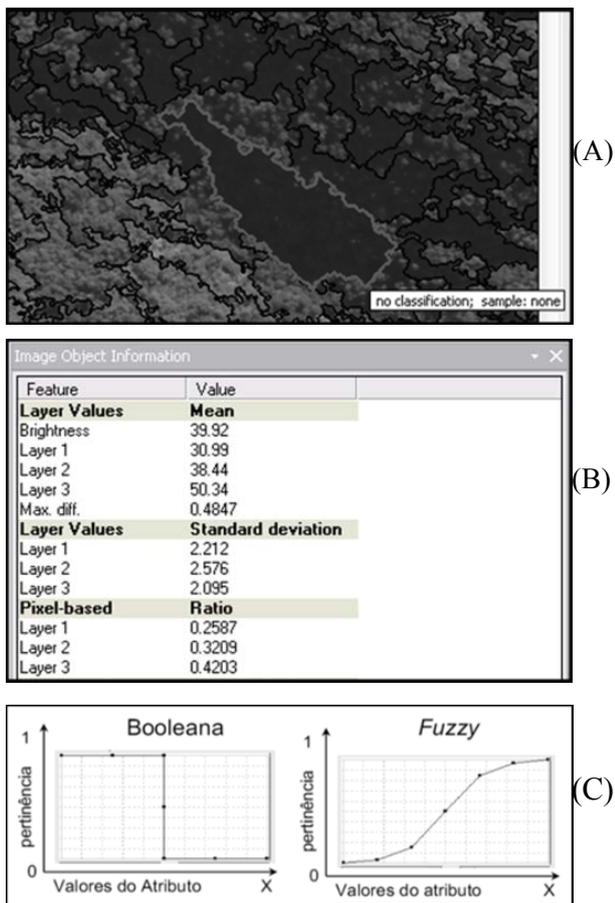


Fig. 3 – (a) Janela de seleção e análise de objetos, (b) tabela de características espectrais dos objetos; e (c) tipos de funções de pertinência.

eCognition®. Na matriz avaliaram-se os erros de omissão (amostras que não foram classificadas de acordo com as classes de referência) e os erros de comissão (amostras de referência classificadas erroneamente como pertencentes a outras classes), além dos tradicionais índices: exatidão global, exatidão do produtor, exatidão do usuário e índice Kappa (CONGALTON; GREEN, 2009).

3. RESULTADOS E DISCUSSÃO

Os resultados são apresentados sequencialmente no que tange a definição de parâmetros de segmentação, metodologia utilizada e geração do mapa temática e sua devida aferição de acuracidade.

3.1 Segmentação

Depois de analisar os diferentes resultados da fase de teste da segmentação, citada no item 2.2, utilizaram-se os valores testados para o intervalo de 0,1-0,4 para a forma e de 0,2-0,4 para compacidade. A verificação da qualidade

para as diferentes combinações dos parâmetros foi feita através da análise visual, comparando-se a forma e o tamanho dos objetos formados, bem como sua representatividade. Por final, foi escolhida a segmentação que atendia melhor aos propósitos do estudo (estágios sucessionais), sendo eles: 0,2 para o critério forma e 0,3 para a compacidade, com um fator de escala de 280.

A segmentação “ideal” sempre vai depender do objetivo do trabalho, da resolução da imagem e das características da região e da vegetação de estudo. De acordo com Silva (2012), o nível de detalhamento alcançado em um mapeamento por meio da análise orientada a objetos deve-se à resolução espacial, sendo que uma área altamente fragmentada e heterogênea necessita de valores de escala mais baixos, de modo que cada objeto formado contenha apenas *pixels* daquela classe. Comportamento este, que foi verificado na fase de testes da segmentação, sendo que o aumento do critério forma o resultado afastava-se do objetivo do estudo que era segmentar todas as classes identificáveis na imagem, e valores baixos de forma, por outro lado, segmentavam objetos demais (Fig. 4).

3.2 Mapa temático

Na Tabela 1 são apresentados os atributos

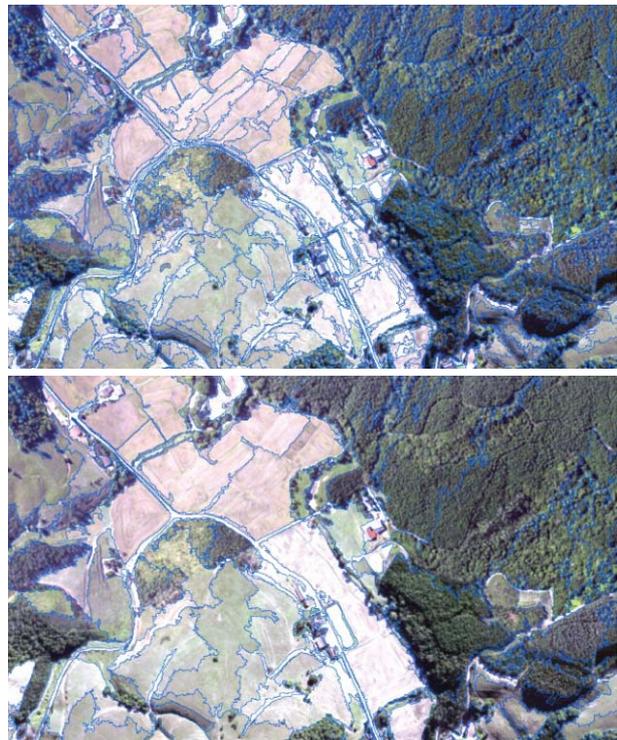


Fig. 4 - Verificação dos cenários: escala “100” (acima) e escala “300” (abaixo) sob os mesmos parâmetros de forma (0.1) e compacidade (0.1).

selecionados para diferenciar as classes de uso do solo: o valor normal (N), ou seja, aquele valor presente em todas as amostras analisadas daquela classe de uso do solo, e o valor extremo (E) que ocorria em setores heterogêneos das amostras de uma classe de uso do solo, de acordo com a função de decaimento (Fig. 3b). Para determinar o valor E, utilizaram-se apenas funções de pertinência por meio da lógica *Fuzzy*, para definir o grau de adesão do objeto à classe de uso do solo. Os intervalos entre os valores N e E são definidos para considerar variações espectrais de classes e objetos.

Na Fig. 5 constam a imagem e o mapa temático gerado.

3.3 Avaliação da classificação

A tabela 5 apresenta a matriz de erros da classificação gerada. O índice de exatidão geral atingido foi de 86% e o índice de Kappa alcançou 0,84, representando um bom resultado, de acordo com Landis e Koch (1977). De modo geral, os índices de exatidão do produtor e de usuário de todas as classes foram superiores a 60% e 50%,

Classes	Floresta estágio inicial	Floresta estágio avançado	Solo Exposto	Lago	Área agrícola	Floresta plantada	Sombra	Área urbana
Brilho	N	58	42	126	113	73	50	58
	E	57	41	125	110	72	49	57
	N	103	85	-	175	148	76	59
	E	105	85,5	-	176	155	78	61
Média Banda 1	N	54	36	147	134	78	44	54
	E	53	35	145	130	74	43	53
	N	105	87	-	207	170	75	52
	E	115	87,5	-	209	175	76	51,0
Média Banda 3	N	54	52	101	68	53	-	54
	E	53	51	100	67	52	-	53
	N	85	76	-	130	69	63	85
	E	86	76,5	-	136	70	65	86
Máxima diferença	N	0,11	-	0,28	0,34	0,13	0,09	0,11
	E	0,1	-	0,27	0,33	0,12	0,1	0,1
	N	0,32	-	0,45	0,37	0,24	0,39	0,32
	E	0,36	-	0,45	0,375	0,25	0,395	0,36
Desvio Padrão Banda 1	N	12	11	12	-	4,4	8	12
	E	11	10,5	10	-	4,6	7	11
	N	22,8	21	-	-	20	18,5	22,8
	E	23	21,2	-	-	20,5	19	23
Desvio Padrão Banda 3	N	6	4,5	8	-	2,8	4	6
	E	4,5	5	9	-	2,5	4,1	4,5
	N	12,8	11,5	-	-	13,5	7,9	5,9
	E	13	12,5	-	-	13,6	8,5	6
Razão Banda 1	N	0,300	0,26	-	-	0,34	0,28	0,300
	E	0,295	0,255	-	-	0,335	0,29	0,295
	N	0,37	0,34	-	-	0,385	0,33	0,37
	E	0,60	0,345	-	-	0,395	0,34	0,60
Razão Banda 3	N	0,23	0,290	-	-	0,255	-	0,23
	E	0,24	0,285	-	-	0,25	-	0,24
	N	0,33	0,39	-	-	0,307	-	0,33
	E	0,335	0,395	-	-	0,31	-	0,335
Menor valor do pixel Banda 1	N	20	16	47	-	30	21	20
	E	18	15	45	-	29	20	18
	N	50	42	-	-	129	43	41
	E	51	42,5	-	-	130	44	42
Maior valor do pixel Banda 1	N	125	98	200	-	76	-	125
	E	120	97	199	-	75	-	120
	N	178	189	-	219	-	179	112
	E	220	190	-	220	-	180	113
Área	N	-	-	-	9500	-	-	-
	E	-	-	-	10000	-	-	-

Legenda: N valor normal da classe; E valor extremo de uma classe.

Tabela 4: Atributos e valores N/E de diferenciação utilizados nas funções de pertinência por classe de uso do solo

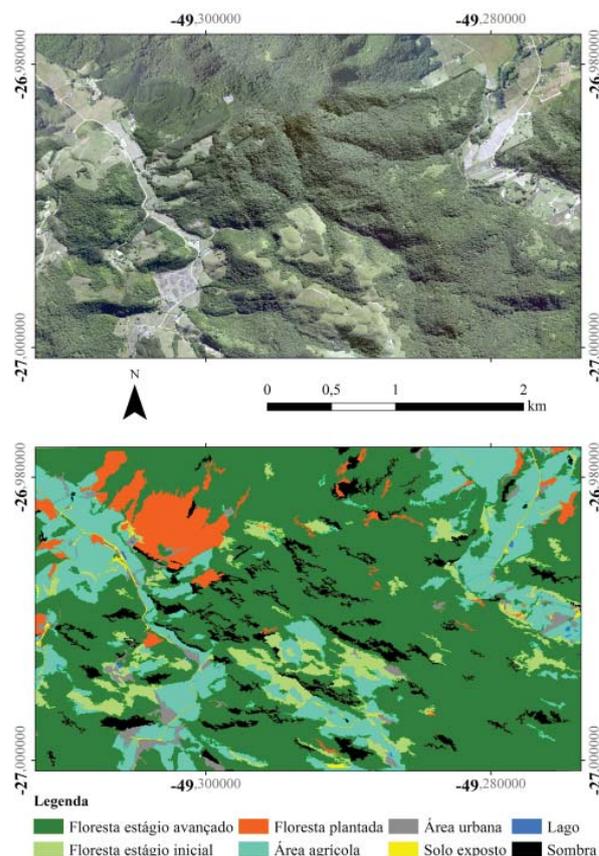


Fig. 5 – (A) Imagem de alta resolução espacial do sensor SA-API (obtida em 2011) na composição 321 (RGB) da área de estudo; (B) mapa temático. Datum: WGS 84.

Tabela 5: Matriz de confusão do mapa temático

Classes	Amostras de referências								Total coletadas
	F. estágio inicial	F. estágio avançado	F. plantada	Área agrícola	Área urbana	Sombra	Lago	Solo exposto	
Classificadas	F. estágio inicial	47	0	0	1	0	0	0	48
	F. estágio avançado	11	57	10	0	1	2	0	81
	F. plantada	0	0	19	0	0	1	0	20
	Área agrícola	5	0	0	56	4	0	0	65
	Área urbana	2	0	0	1	34	0	0	39
	Sombra	0	0	2	0	0	37	0	39
	Lago	0	0	0	0	0	0	12	12
	Solo exposto	0	0	0	0	1	0	0	29
	Não Class.	1	0	0	0	1	0	0	3
Total coletadas	66	57	31	58	41	40	12	32	-
Exatidão (produtor)	0,71	1	0,61	0,96	0,83	0,92	1	0,90	0,86
Exatidão (usuário)	0,97	0,70	0,95	0,86	0,87	0,92	1	0,96	
Kappa por classe	0,66	1	0,58	0,95	0,80	0,91	1	0,89	

respectivamente.

Verificou-se que as classes floresta em estágio inicial e floresta plantada apresentaram os maiores erros de omissão (quando um objeto não é incluído na classe que pertence); nessas classes ocorreu principalmente confusão com a classe floresta em estágio avançado. Entretanto, as classes estágio inicial e floresta plantada tiveram uma exatidão do usuário satisfatória (não foram classificadas como pertencentes a outras classes), com 97% e 95%, respectivamente. Desta forma, levando em consideração os resultados anteriores, o índice de Kappa para as classes estágio inicial e floresta plantada foi de 0,66 e 0,58, respectivamente. Estas duas classes apresentaram heterogeneidade espectral maior, pela sua variabilidade natural (no caso da floresta em estágio inicial, constituída trechos com vegetação herbácea, herbácea-arbustiva e arbustiva-arbórea) e por serem reflorestamentos de pequenos proprietários rurais que apresentam maior mortalidade, sub-bosque de vegetação nativa e deficiências silviculturais do que plantações empresariais, influenciando negativamente os resultados obtidos.

A classe floresta em estágio avançado não apresentou erros de comissão, com exatidão do usuário de 100%, porém, esta classe apresentou o pior índice de exatidão do usuário, devido aos erros de classificação em relação as classes estágio inicial e floresta plantada. O índice de Kappa para o estágio avançado foi de 100%.

As outras classes apresentaram erros de produtor e de usuário acima de 80%, com o maior erro de produtor na classe área urbana (83%), e do usuário na classe área agrícola (86%). A classe área urbana apresentou confusão com as classes inicial, área agrícola e solo exposto, obtendo um índice de Kappa de 80%. Setores da classe área agrícola foram confundidos com a classe floresta em estágio inicial e com a classe área urbana, atingindo um Kappa de 95%.

Para a classe lago, na qual se utilizou um atributo espacial (área) conseguiu-se uma acurácia de 100% para todos os índices avaliados.

4. CONCLUSÕES E RECOMENDAÇÕES

Considerando-se resultado do índice Kappa, pode-se afirmar que o mapa temático gerado a partir apenas das bandas do visível, utilizando descritores espectrais e espaciais,

apresentou desempenho satisfatório (LANDIS; KOCH, 1977), uma vez que a maioria dos índices de acuracidade é superior a 80%. Os melhores desempenhos do índice Kappa foram obtidos para as classes floresta em estágio avançado, lago, área agrícola (cultivos e pastagens); sombra, solo exposto e área urbana; os piores foram obtidos para as classes floresta em estágio inicial e floresta plantada, devido à heterogeneidade das áreas destas classes. O uso das bandas do infravermelho, não disponíveis para o presente estudo, certamente possibilitará a obtenção de maior acuracidade da classificação. O mesmo vale para a inclusão do uso de índices de vegetação, de modelos digitais de terreno e de superfície, como dados de entrada e o processamento dos dados por meio de técnicas de mineração de dados (*data mining*).

Por outro lado, este trabalho demonstrou a importância e a eficiência da segmentação automática e da análise tabular dos atributos espectrais e espaciais adquiridos por amostragem aleatória de referência, para posterior transformação destas informações em funções de pertinência no *software* utilizado.

AGRADECIMENTOS

Agradecemos à Secretaria de Estado do Desenvolvimento Econômico Sustentável (SDS-SC) pela cessão das imagens, à CAPES pela concessão da bolsa de mestrado do primeiro autor e ao CNPq pela bolsa de produtividade de pesquisa do segundo autor.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, C. D.; SOUZA, I. M.; PEREIRA, M. N. Análise orientada a objeto para extração automática de áreas urbanizadas. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. Anais... São José dos Campos: INPE, 2007. Artigos, p. 5187-5189.

BAATZ, M.; SCHAPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, J; Blaschke, T. (Eds). *Angewandte, Geogr. Informationsverarbeitung XII*. Heidelberg: Wichmann, p. 12-23, 2000.

BARRETT, E. C.; CURTIS, L. *Introduction to environmental remote sensing*. Londres: Chapman & Hall, 1992. 426p.

- BATISTA, M. H. Classificação hierárquica orientada a objeto em imagens de alta resolução espacial empregando atributos espaciais e espectrais. 199p. Dissertação (Mestrado em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul (UFRGS), Rio Grande do Sul, RS. 2006.
- BORMANN, F. H.; LIKENS, G. E. Pattern and process in a forested ecosystem. Springer-Verlag, New York Inc, 253 p., 1979.
- BRASIL. Resolução nº 4, de 04 de maio de 1994. Estabelece definições e parâmetros mensuráveis para análise de sucessão ecológica da Mata Atlântica no Estado de Santa Catarina. 5p, 1994. Disponível em: <http://www.mp.ba.gov.br/atuacao/ceama/material/legislacoes/flora/resol_conama_05_94.pdf> Acesso em: 10 setembro 2012.
- CADENA, G. T. Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise orientada a objeto. 114p. Dissertação (Mestrado em Ciências Cartográficas). Universidade Estadual Paulista, Presidente Prudente, SP. 2011
- CASTILHO, M.; BENOIT, R.; SANHCHEZ-AZOFEIFA, A.; CALVO-ALVARADO, J.; DUBAYAH, R. LIDAR remote sensing for secondary Tropical Dry Forest identification. *Remote sensing of environment*, v. 121, p. 131-143. 2012.
- CENTENO, J. A. S.; ANTUNES, A. F. B.; TREVIZAN, S.; CORREA, F. Mapeamento de áreas permeáveis usando uma metodologia orientada a regiões e imagens de alta resolução. *Revista Brasileira de Cartografia*, 55 (01), p. 48-56, 2003.
- CHOKKALINGAM, D.; JONG, W. D. Secondary forest: a working definition and typology. *Internacional forestry Review*, v. 3, (1), p. 19-26. 2001.
- CLARK, M. L.; AIDE, T. M.; GRAU, H. R.; RINER, G. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America. *Remote Sensing of Environment*, v 114, p. 2816-2832. 2010.
- CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. New York: Lewis Publishers, 136 p, 1999.
- DEAN, W. A ferro e fogo: a história e a devastação da Mata Atlântica brasileira. Companhia das Letras, 484 p. 1997.
- DEFINIENS. Definiens eCognition developer 8: reference book. Definiens AG, Trappentreustr. 1, München, Germany 276 p, 2009.
- DINERSTEIN, E.; OLSON, D. M. GRAHAM, D. J.; LEDEC, G.; WEBSTERET, A. L. Una evaluación del estado de conservación de las ecoregiones terrestres de América Latina y el Caribe. Washington D.C.: Fondo Mundial para la Naturaleza, 1995.
- DUBOIS, J. C. L. Secondary forests as a land-use resource in frontier zones of Amazonia. In: ANDERSON, A. B. (Ed.) Alternatives to deforestation: steps toward sustainable use of the Amazon rain forest. New York, USA. p. 183-194. 1990.
- ENGEMAP Geoinformação. Relatório de produção final - edital de concorrência pública nº 0010/2009. Florianópolis SC. 218p. 2012.
- FRANCISCO, C. N.; ALMEIDA, C. M. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. *Boletim de Ciências Geodésicas*, Curitiba, v. 18 (2), p. 302 - 326, 2012.
- GONZÁLEZ, R. C.; WOODS, R. E. Processamento de Imagens Digitais. 509 p. Edgard Blücher Ltda. São Paulo, 2000.
- HOLDRIDGE, L. R. Life zone Ecology. San Jose, CA: Tropical Science Center, p. 60-77. 1967.
- JENSEN, J R. Introductory digital image processing (3 ed.). New Jersey: Pearson Prentice Hall, 526 p, 2005.
- KLEIN, R. M. Mapa Fitogeográfico do Estado de Santa Catarina. Itajaí: Herbário Barbosa Rodrigues, 1978.
- KRESSLER, F. P.; STEINNOCHER, K. Image data and LIDAR – an ideal combination matched by object oriented analysis. In: *Geographic Object-Based Image Analysis*, 1, 2006, Salzburg

- University, Austria. Proceedings..., 6 p., 2006.
- LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, p. 159 - 174, 1977.
- LIEBSCH, D.; MARQUES, M. C. M.; GOLDENBERG, R. How long does the Atlantic Rain Forest take to recover after a disturbance? Changes in species composition and ecological features during secondary succession. *Biological Conservation*, Kidlington, v. 141 (6), p. 1717-1725, 2008.
- LUGO, A E. The apparent paradox of reestablishing species richness on degraded lands with tree monocultures. *Forest Ecology and Management*, v. 99, p. 9-19. 1997.
- MARPU, P. R. Geographic Object-based Image Analysis. Freiberg, 2009. 121f. Tese (Doutorado em Engenharia) - Faculty of Geosciences, Geo-Engineering and Mining Technische Universität Bergakademie Freiberg, 2009.
- MEINEL, G.; NEUBERT, M. A Comparison of segmentation programs for high resolution remote sensing data. *Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences*. p. 1097-1102, 2005.
- MONTEIRO, A.; LINGNAU, C.; SOUZA Jr, C. Classificação orientada a objeto para detecção da exploração seletiva de madeira na Amazônia. *Revista Brasileira de Cartografia* v. 59 (03), p. 225-234, 2007.
- MOREIRA, M. A. Fundamentos de sensoriamento remoto e metodologias de aplicação. 3 ed. 320p. Viçosa: Universidade Federal de Viçosa, 2005.
- NOVO, E. M. L. Sensoriamento remoto. São Paulo: Edgard Blucher Ltda, 387 p., 1998.
- OLIVER, C. D. Forest development in Noth America following major disturbances. *Forest Ecology and Management*, v. 3, p. 153-168. 1981.
- PINHO, C. M. D. Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada á classificação de cobertura de solo no espaço intra-urbano: o caso de São José dos Campos - SP. 2006. 180 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2006.
- PRADO, B. R.; MARTINS, V. A.; HAYAKAWA, E. H.; JÚNIOR, J. B. T.; SHIMABUKURO, Y. E. Identificação de classes de cobertura da terra na Amazônia utilizando imagens ALOS/PALSAR e classificação orientada a objeto. *Revista Brasileira de Cartografia*, v. 62 (03), p. 563-569, 2010.
- RIBEIRO, M. C.; METZGER, J. P.; MARTENSEN, A. C.; PONZONI, F. J.; HIROTA, M. M. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. *Biological Conservation*, v. 142, p. 1141-1153. 2009.
- SCHUCH, C.; SIMINSKI, A.; FANTINI, A. C. Usos e potencial madeireiro do jacatirão-açu (*Miconia cinnamomifolia* (De Candolle) no litoral de Santa Catarina. *Floresta* (UFPR. Impresso), v. 38, p. 735-741, 2008.
- SIMINSKI, A.; FANTINI, M, A.C.; REIS, M. S. Classificação da vegetação secundária em estágios de regeneração da Mata Atlântica em Santa Catarina. *Ciência Florestal*, Santa Maria, v. 23 (3), p. 369-378, 2013.
- SILVA, P. R. Uso de uso de redes neurais artificiais e objetos geográficos na classificação digital de imagens de sensoriamento remoto. 86p. Dissertação (Mestrado em Ciências Florestais). Universidade Federal de Lavras (UFLA), Lavras, MG. 2012.
- SOUZA Jr, C., MONTEIRO, A., BARRETO, P. Exploração madeireira na Amazônia: é possível monitorar por satélite? *Ciência Hoje*, v. 197, p. 62-65, 2003.
- TEIXEIRA, A. M. G., SOARES-FILHO, B. S., FREITAS, S. R., METZGER, J. P. Modeling landscape dynamics in an Atlantic Rainforest region: implications for conservation. *Forest Ecology and Management* 257, 1219–1230. 2009
- TUCKER, C. J.; TOWNSHEND, J. R. G. Strategies for monitoring tropical deforestation using satellite data. *International Journal of Remote Sensing*, v. 21 (6), p. 1461-1471. 2000.
- VIBRANS, A. C. A cobertura florestal da Bacia do Rio Itajaí: elementos para uma análise histórica. Tese (Doutorado). Florianópolis:

Universidade Federal de Santa Catarina (USFC), Centro de Filosofia e Ciências Humanas. 257 p, 2003.

VIBRANS, A. C., SEVEGNANI, L., GASPER, A. L., LINGNER, D. V. (Eds). Inventário Florístico Florestal de Santa Catarina, vol. I. Diversidade e conservação dos remanescentes florestais. Blumenau. Edifurb. 177p, 2012.

VIBRANS, A. C., McROBERTS, R. E., MOSER, P.; NICOLETTI, A. L. Using satellite image-based maps and ground inventory data to estimate the remaining Brazilian Atlantic forest in Santa Catarina. *Remote Sensing of Environment*, v. 130. p. 87-95 2013.

VIEIRA, I. C. G.; ALMEIDA, A. S.; DAVIDSON, E. A.; STONE, T. A.; CARVALHO, C. J. R.; GUERRERO, J. B. Classifying successional forests using Landsat spectral properties and ecological characteristics in eastern Amazônia. *Remote Sensing of Environment*, v. 87, p- 470-481. 2003.

WHITMORE, T. C.; BURSLEM, D. F. R. P. Major disturbances in tropical rainforests. In: NEWBERRY, D. M.; PRINS, H. H. T.; BROWN, N. D. (Eds.) *Dynamics of tropical communities*. p. 549-565. Oxford: Blackwell Science Ltd, 1998.