

TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS E MINERAÇÃO DE DADOS APLICADAS AO MAPEAMENTO DE FRAGMENTOS FLORESTAIS A PARTIR DE IMAGENS ETM+

Digital Image Processing Techniques and Data Mining
Applied to the Mapping of Forest Fragment from ETM+
Imagery

Pedro José Farias Fernandes¹
Raphael e Silva Girão²
Laerte Costa e Silva³

¹Laboratório de Geografia Física/
Universidade Federal Fluminense – UFF

²Museu Nacional/ Pós-Graduação em
Geologia do Quaternário/ Universidade
Federal do Rio de Janeiro - UFRJ

³Instituto de Pesquisa e Planejamento
Urbano e Regional / Universidade Federal do
Rio de Janeiro - UFRJ

Resumo

O presente trabalho tem como objetivo apresentar uma metodologia para classificar, de forma automática, fragmentos florestais do município de São José de Ubá (RJ), utilizando técnicas de processamento digital de imagens e mineração de dados em imagens ETM+/Landsat 7. Primeiramente, foi feita a restauração das imagens ETM+ para eliminar o aspecto borrado das imagens. Em seguida, usou-se o método IHS (*Intensity/Hue/Saturation*) de fusão entre as bandas 3, 4 e 5 (com resolução de 30 m) e a banda pancromática (com resolução de 15 m) por permitir a adição de um alto grau de detalhe nas bandas originais. O passo seguinte foi a aplicação de um filtro 5x5 de coocorrência sobre as bandas fusionadas que gerou 24 imagens referentes aos atributos texturais das bandas fusionadas. Posteriormente, coletou-se amostras de pixels das 3 bandas fusionadas e das 24 imagens geradas das duas classes estabelecidas: "Floresta" e "Não Floresta". Depois, essas amostras foram exportadas para o formato ASCII e foram inseridas em um *software* de mineração de dados que gerou uma árvore de decisão, a partir do algoritmo C4.5, utilizada na classificação. Obteve-se, como resultado, um mapa de fragmentos florestais com Kappa igual a 0,765. É possível observar que o município sofreu um processo de fragmentação florestal, possuindo aproximadamente 27,28% de cobertura vegetal. Nota-se que as áreas mais preservadas estão ao longo das margens de rios e em relevos declivosos das fronteiras oeste e sul/sudeste. Finalmente, pode-se concluir que a metodologia desenvolvida foi eficaz para alcançar o objetivo deste estudo.

Palavras-chave: Sensoriamento Remoto, Geoprocessamento, Vegetação.

Abstract

The present work aims to develop a methodology to classify, automatically, forest fragments of São José de Uba (RJ), using digital image processing and data mining techniques in ETM +/Landsat 7 data. First, restoration of ETM + was done to eliminate the appearance of blurred images. Thereafter, the IHS (*Intensity/Hue/Saturation*) fusion method was used between bands 3, 4 and 5 (with 30 m resolution) and

Correspondência:

Pedro Fernandes
Universidade Federal Fluminense – Instituto
de Geociências - Laboratório de Geografia
Física - Av. Litorânea s/n - Campus da Praia
Vermelha, Boa Viagem, Niterói, CEP: 24030-
346 - RJ.
E-mail: pjff@dsr.inpe.br

Recebido em junho de 2012
Aprovado em janeiro de 2013
Artigo disponível em
www.cadegeo.uff.br

panchromatic band (with a resolution of 15 m) to allow the addition of a high degree of detail in the original bands. The next step was the application of the co-occurrence filtering, size 5x5, in the fused bands that generated 24 images related to textural attributes of the fused bands. Subsequently, samples of pixels of the two classes "Fragment" and "No Forest" were collected from the 3 fused bands and from the 24 images generated. Then these samples were exported to ASCII format and were entered into a data mining software, that generated a decision tree (used in the classification) from the C4.5 algorithm. As a result, a map of forest fragments with Kappa equal to 0.765 was obtained. The final map shows that the municipality suffered a forest fragmentation process, with approximately 27.28% of vegetation cover. The most preserved areas are along the rivers' banks and on slopes in the west and south/southeast borders. Finally, it can be concluded that the methodology was effective in achieving the objective of this study.

Keywords: Remote Sensing, Geoprocessing, Vegetation.

INTRODUÇÃO

A preservação da cobertura vegetal é fundamental para garantir a qualidade da paisagem. Seu papel é importante para a infiltração da água e manutenção da estabilidade do solo (ARAUJO *et al.*, 2009; GUERRA, 2007). Logo, sua remoção pode acarretar em desequilíbrios ambientais como deslizamentos, ravinas, voçorocas e aumento da carga de sedimentos em cursos fluviais (CUNHA e GUERRA, 2006).

Caso a cobertura florestal de uma localidade esteja fragmentada, pode estar ocorrendo desmatamento da vegetação nativa causado por diversos fatores. Greggio *et al.* (2009) menciona que os aspectos mais graves do processo de fragmentação florestal são o efeito de borda, que é uma mudança na composição e abundância de espécies nas margens de um fragmento, e a redução da biodiversidade.

Uma das maneiras de conhecer a situação da cobertura florestal, e assim estabelecer ações de monitoramento ambiental, de uma área é pela identificação de fragmentos florestais. Nesse contexto, o Sensoriamento Remoto emerge como uma fonte de dados da superfície terrestre, podendo ser utilizado na classificação da cobertura florestal (ANDERSON, 2004), e, conseqüentemente, na detecção de fragmentos florestais.

Porém, o mapeamento de fragmentos requer imagens com detalhes da forma dos alvos. E, muitas vezes, durante o processo de formação das imagens orbitais, o sinal registrado pelo sensor é degradado, resultando na perda de detalhes nas imagens (BOGGIONE, 2003). Diante disto, o desenvolvimento de metodologias de classificação de fragmentos florestais voltado para o melhoramento da definição geométrica dos alvos, é necessário para a realização de trabalhos de qualidade.

Há processamentos de imagem úteis para esse tipo de mapeamento, como a restauração para recuperar o sinal degradado durante a formação das imagens (FONSECA *et al.*, 1993), a fusão para combinar os detalhes geométricos da banda pancromática (PAN) com a informação espectral das imagens multiespectrais (MS) (FONSECA *et al.*, 2011), e a extração de atributos de textura das imagens para aumentar a separabilidade entre classes (ANGELO, 2000).

Tendo em vista que há grande variedade de atributos espectrais e texturais dos alvos presentes em uma imagem de Sensoriamento Remoto, a mineração de dados pode aumentar o potencial da utilização dos dados orbitais (KORTING *et al.*, 2008). A mineração de dados envolve o uso de algoritmos para a compreensão inteligente dos dados e extração dos padrões úteis na produção de um modelo de conhecimento (FAYYAD *et al.*, 1996). Neste trabalho, o modelo de conhecimento produzido veio na forma de uma árvore de decisão, que é uma representação concisa de regras na forma de fluxograma. Tais regras podem ser utilizadas na classificação de imagens (WITTEN; FRANK; HALL, 2011; CARVALHO, 2011).

Há trabalhos que mostram que esses processamentos são úteis na classificação de alvos na superfície. Coura *et al.* (2010) e Coura (2006) utilizam a restauração para identificar classes de vegetação. Carvalho *et al.* (2011) mostram o potencial da fusão para o mapeamento de fragmentos florestais. Novack *et al.* (2008) e Adami *et al.* (2007) também utilizam a fusão na classificação do uso e cobertura do solo. Vieira *et al.* (2012), Vieira (2010) e Novack (2009) classificam imagens a partir de árvores de decisão geradas por mineração de dados.

Desse modo, admite-se a hipótese de que uma metodologia para mapeamentos de fragmentos florestais, a partir de dados orbitais, que envolva processamentos para realçar/recuperar detalhes dos alvos em superfície, mineração de dados e classificação de atributos texturais, produza bons resultados. Portanto, o objetivo é desenvolver uma metodologia para classificar, de forma automática, os fragmentos florestais do município de São José de Ubá (RJ), utilizando restauração de imagens, técnica de fusão IHS, atributos texturais e mineração de dados, a partir de imagens ETM+/Landsat 7.

MATERIAIS E MÉTODOS

Área de Estudo

O município de São José de Ubá fica localizado na Região Noroeste Fluminense do Estado do Rio de Janeiro (Figura 1), entre as latitudes 021° 17' 15" S e 021° 29' 20" S, e longitudes 041° 48' 50" W e 042° 03' 30" W aproximadamente.

A região era caracterizada, inicialmente, pela presença de Mata Atlântica (FERNANDES, 2010). Porém, a mata nativa foi reduzida devido à entrada das atividades agropecuárias, além de não ter havido uma preocupação com o manejo do solo e erosão do solo (MOURA, 2005).

São José de Ubá conta com um relevo predominantemente colinoso, e possui alinhamentos serranos e colinas dissecadas nas fronteiras oeste, norte e sul. O clima da área pode ser definido como do tipo Aw, de acordo com a classificação de Köppen, indicando um clima tropical com estação seca durante o inverno (FERNANDES, 2010).

A situação ambiental da área de estudo é problemática, já que as atividades agrícolas em São José de Ubá degradaram o solo, intensificaram os processos erosivos, estenderam-se em áreas protegidas pela lei, e aumentaram o risco de contaminação devido ao uso de agrotóxicos no cultivo de tomate (MOURA, 2005).

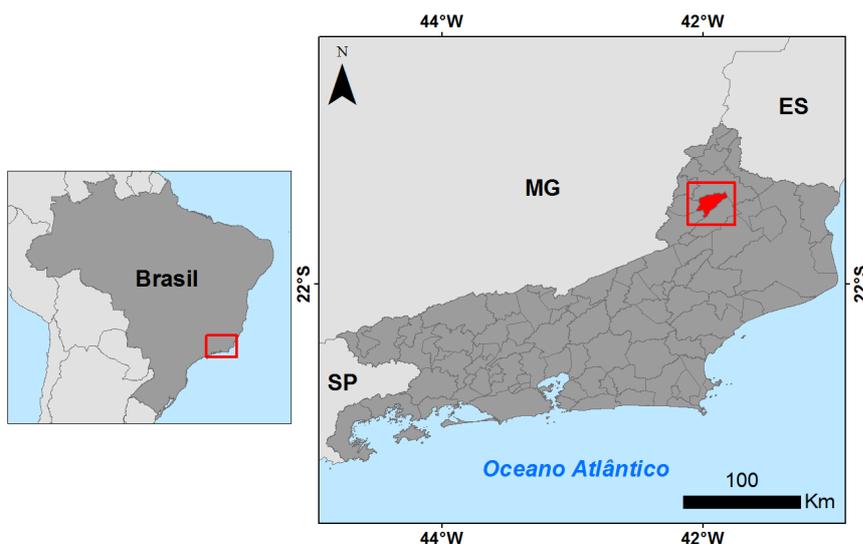


Figura 1. Localização de São José de Ubá no Estado do Rio de Janeiro.

Análise de imagem

A metodologia (Figura 2) envolveu as seguintes etapas para atingir os resultados: restauração de imagens, uso do método de fusão IHS, extração de atributos de textura, mineração de dados, classificação e avaliação.

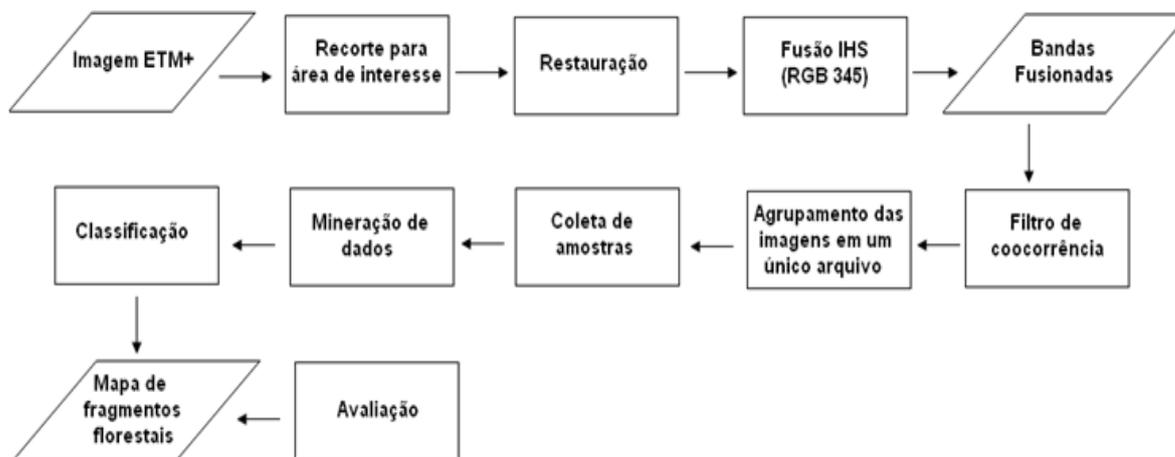


Figura 2. Fluxograma que resume a metodologia utilizada.

Foi utilizada uma imagem do sensor ETM+ do ano de 2001 a bordo do satélite Landsat 7, da órbita/ponto 216/75. Por não haver disponibilidade de imagens a partir de 2003 para a área e devido ao fato da presença de nuvens que afetariam a eficácia dos resultados, nas outras imagens, a imagem do ano de 2001 foi selecionada por ser a mais atual e com a menor cobertura de nuvens.

Foram adquiridas as bandas 1, 2, 3, 4, 5 e 7, com resolução espacial de 30 m, e a banda pancromática (PAN) com resolução espacial de 15 m. A imagem está disponível no catálogo de imagens do Instituto Nacional de Pesquisas Espaciais (<http://www.dgi.inpe.br/CDSR/>).

Os dados foram tratados em quatro *softwares*: ENVI 4.3 e SPRING 5.1.6 para o processamento digital das imagens ETM+, WEKA 3.6 para realizar a etapa de mineração de dados, e ArcGIS 9.2, utilizado na elaboração do cartograma final.

Restauração de imagens

As imagens orbitais, quando geradas, podem ser afetadas por diferentes fatores que causam a degradação do sinal, resultando em uma resolução espacial efetiva menor do que a resolução espacial nominal (FONSECA *et al.*, 1993). A degradação do sinal faz com que as imagens tenham um aspecto borrado, que caracteriza a perda de detalhes dos alvos na superfície (BOGGIONE, 2003). A aplicação da restauração corresponde ao estágio de pré-processamento das imagens, e serve para recuperar o sinal degradado e melhorar a resolução espacial efetiva de um sistema sensor (BOGGIONE, 2003). Tal processamento é feito pela aplicação de um filtro linear nas imagens cujos pesos foram obtidos a partir da modelagem da degradação do sinal com os componentes de um determinado sensor. Este filtro de restauração está implementado no *software* SPRING 5.1.6.

Fusão IHS (Intensity/Hue/Saturation)

A fusão de imagens tem como objetivo gerar um produto híbrido entre imagens multiespectrais, ricas em informações espectrais, e uma imagem pancromática com alta resolução espacial e riqueza em detalhes (FONSECA, 2011). De acordo com Cecchini *et al.* (2011), as técnicas de fusão permitem classificar e detectar alvos nas imagens de maneira mais efetiva.

No presente trabalho, três métodos de fusão foram testados: fusão baseada na Análise de Principais Componentes, fusão baseada na transformação de Gram-Schmidt e a fusão IHS (*Intensity/Hue/Saturation*). Escolheu-se a fusão IHS por ter gerado imagens mais detalhadas.

A fusão IHS fundamenta-se na transformação de três bandas nos canais RGB para o sistema IHS, substituindo a componente I (*Intensity*) pela imagem PAN, e finalmente transformando as imagens do sistema IHS para o RGB (FONSECA *et al.*, 2011). No presente artigo foi feita a fusão IHS sobre as bandas na composição RGB 345 por separar bem a vegetação (em tons verdes) de outros alvos (em tons de lilás).

Extração de atributos de textura

As informações contidas em uma imagem digital estão sob a forma de atributos, que podem ser espectrais, espaciais, temporais, etc. Desse modo, a categoria de atributos espaciais são referentes às características das regiões presentes em uma imagem, como, por exemplo, a forma e textura (ANGELO, 2000).

Atributos de textura são importantes para a identificação de feições em imagens de satélite (HARALICK *et al.*, 1973), e podem aumentar a separabilidade entre classes que são espectralmente semelhantes, porém distintas texturalmente, o que permite uma classificação com melhor exatidão (ANGELO, 2000).

A textura é uma propriedade que reflete o arranjo estrutural de uma superfície e sua relação com a vizinhança (HARALICK *et al.*, 1973). Para a extração de atributos texturais, foi aplicado um filtro de tamanho 5x5 de coocorrência sobre as bandas 3,4 e 5 fusionadas, que verificou a frequência de ocorrência relativa de cada par de valores de *pixel* com determinadas separação e orientação (ANGELO, 2000). Estas três bandas foram utilizadas na extração de atributos texturais pois foram as três imagens geradas pelo método de fusão IHS.

Mineração de dados

Após a obtenção das 24 imagens de textura, foi feito o agrupamento destas 24 imagens com as 3 bandas fusionadas, totalizando 27 imagens dentro de um mesmo arquivo. Posteriormente, amostras das classes "Fragmento" e "Não-Floresta" foram coletadas nas

imagens. Essas amostras foram exportadas para o formato ASCII, e convertidas para o formato de tabela CSV, para dar entrada no *software* de mineração de dados WEKA 3.6.

A mineração de dados é um estágio para a descoberta de conhecimento em bases de dados, sendo responsável pela extração de conhecimento em grandes quantidades de dados (CARVALHO, 2011). A construção de um modelo de conhecimento é feita pelo emprego de algoritmos específicos para compreensão inteligente dos dados e extração de padrões (FAYYAD *et al.*, 1996). O modelo de conhecimento construído pode ser expresso na forma de uma árvore de decisão, que pode ser aplicada na classificação de imagens de Sensoriamento Remoto (VIEIRA, 2010). Sendo assim, a mineração de dados identifica os atributos que permitem a maior separabilidade entre classes, reduzindo, como consequência, o uso de inúmeros atributos que podem resultar em uma classificação não satisfatória.

Após a entrada dos dados em formato CSV no WEKA 3.6, foi executada a mineração de dados pelo algoritmo C4.5 (disponibilizado no WEKA 3.6 como J48) que construiu um modelo de conhecimento na forma de árvore de decisão que foi utilizada no processo de classificação de imagens no *software* ENVI 4.3. A aplicação do algoritmo C4.5 no presente trabalho é justificada pelo seu bom desempenho em trabalhos anteriores de Sensoriamento Remoto (VIEIRA, 2012; CARVALHO, 2011; NOVACK, 2009).

Classificação e avaliação

A árvore de decisão obtida pelo *software* WEKA 3.6 foi construída no ENVI 4.3. Posteriormente, foi feita a classificação dos fragmentos florestais, que permitiu a criação de um mapa de fragmentos florestais do município de São José de Ubá. Para que os mapas sejam cientificamente válidos, é necessário fornecer o erro que está associado a esses mapas (MCROBERTS, 2011). Com esse objetivo, 150 amostras foram selecionadas aleatoriamente nas imagens. Posteriormente, foi realizada a rotulação de cada amostra de acordo com a sua classe ("Fragmento" ou "Não-Floresta"), com base em trabalho de campo e interpretação de fotografias aéreas.

A avaliação da classificação foi feita com o índice Kappa, que define uma medida de acurácia de acordo com a proporção em que uma área é corretamente classificada com base em uma referência, no caso, os pontos selecionados aleatoriamente (CONGALTON, 1991). Desse modo, o índice Kappa varia de 0 (uma classificação muito fraca) até 1 (uma classificação excelente), de acordo com a escala de Landis e Koch (1977), na Tabela 1.

Tabela 1. Avaliação da classificação.

Índice Kappa	Qualidade da classificação
> 0	Muito fraca
0 – 0,2	Fraca
0,2 – 0,4	Razoável
0,4 – 0,6	Boa
0,6 – 0,8	Muito boa
0,8 – 1	Excelente

Fonte: Landis e Koch (1977).

RESULTADOS E DISCUSSÕES

Primeiramente, foi utilizado um filtro de restauração das bandas 1, 2, 3, 4, 5, 7 e PAN do sensor ETM+, implementado no *software* SPRING 5.1.6, que gerou imagens com mais detalhes, melhor informação textural e contornos mais bem definidos (Figura 3). Apesar da diferença entre o antes e depois da restauração ser sutil, é possível verificar que a textura do relevo e de outras feições foi realçada com o procedimento. A restauração de imagens viabilizou a recuperação de detalhes perdidos durante a formação da imagem pelo sistema sensor, o que garantiu fragmentos florestais com contornos mais detalhados. Estes resultados podem ser comparados com os de Coura (2006) e com os de Coura *et al.* (2010), pois tais autores também mostram que a restauração de imagens facilitou a identificação de classes de vegetação devido a um melhor delineamento e ao ganho de detalhes nas bordas.

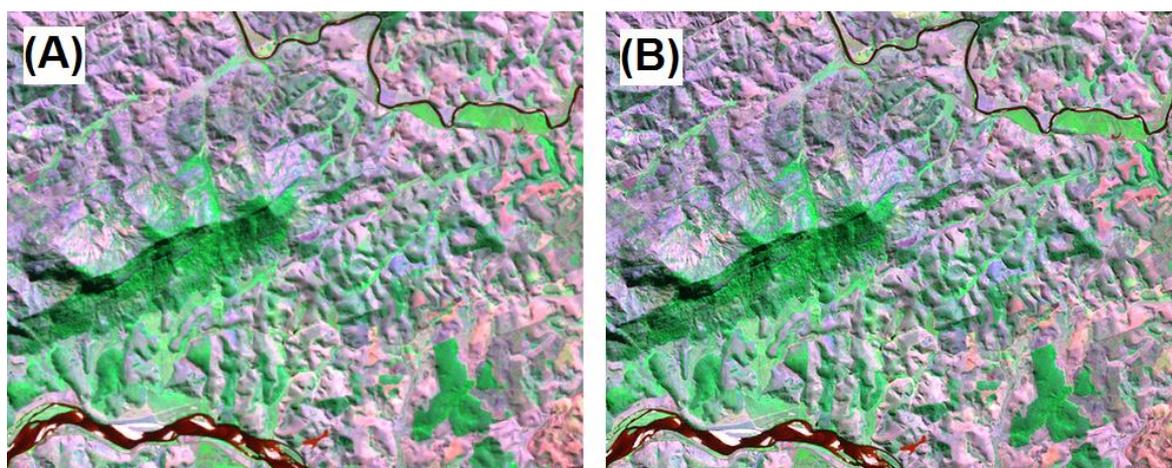


Figura 3. A: Composição RGB 345 com as bandas antes da restauração. B: A mesma composição com bandas restauradas.

A fusão IHS tornou possível a geração de um produto híbrido que combinou as características espectrais das bandas 3, 4 e 5 e a resolução espacial da banda PAN, fazendo com que as bordas dos fragmentos florestais ficassem mais bem definidas em relação às outras técnicas de fusão (Figura 4). Assim, o desempenho da Fusão IHS foi avaliado qualitativamente como a melhor técnica entre as três testadas neste trabalho, sendo considerada excelente, de acordo com a escala de Shi *et al.* (2005). Nota-se, que para o caso específico deste trabalho, não houve grandes diferenças visuais entre a fusão baseada na transformação de Gram-Schmidt e a fusão baseada na Análise de Principais Componentes.

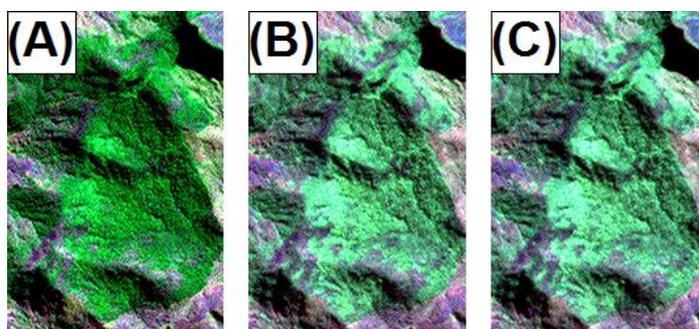


Figura 4. A: Fusão IHS; B: Fusão baseada na transformação de Gram-Schmidt; C: Fusão baseada na Análise de Principais Componentes.

A fusão IHS mostrou-se necessária para a obtenção de feições com bordas detalhadas, favorecendo a extração de atributos texturais referentes a alvos com mais detalhes. Assim como em Adami *et al.* (2007), a fusão IHS facilitou a delimitação de feições na cobertura do solo, e é

uma técnica reconhecida pela sua eficiência e facilidade (TU *et al.*, 2001). Pode-se dizer que o produto híbrido gerado pela fusão permitiu uma melhor obtenção de informação espacial para a classificação dos fragmentos, conforme indicam os resultados de Carvalho *et al.* (2011), que identificaram fragmentos de vegetação arbórea ao utilizar fusão de imagens.

A aplicação do filtro de coocorrência sobre as bandas 3,4 e 5 fusionadas gerou como resultado 24 imagens com informação textural referentes aos seguintes atributos de textura: Média, Variância, Homogeneidade, Contraste, Dissimilaridade, Entropia, Segundo Momento e Correlação. Como o filtro gerou 8 imagens de atributos de textura para cada banda utilizada, o total de imagens relativas a esses atributos resultantes foi de 24.

Coletou-se amostras das classes "Fragmento" e "Não-Floresta" nas 24 imagens de textura e nas 3 imagens fusionadas. As amostras da classe "Fragmento" totalizaram em 21.319 *pixels*, enquanto que as da classe "Não-Floresta" totalizaram em 36.200 *pixels*. Sendo assim, essas amostras foram inseridas no *software* de mineração de dados.

A etapa de mineração de dados permitiu a extração de um modelo de conhecimento implícito nas imagens a partir de relações e padrões entre os dados das imagens (HSU *et al.*, 2002). A mineração de dados, por extrair das imagens informações com significado, como mencionam Hsu *et al.* (2002), identificou os atributos que separam melhor as classes "Fragmento" e "Não-Floresta", otimizando o processo de classificação, uma vez que não utiliza todos os atributos, e sim os que viabilizam maior separabilidade das classes. Logo, a mineração de dados foi eficiente na construção da árvore de decisão (Figura 5), que representa um modelo de conhecimento criado a partir da extração de padrões encontrados nos dados (QI; ZHU, 2003), e na redução da dimensionalidade dos atributos usados na classificação, como mostram os resultados de mapeamento de uso e cobertura do solo obtidos por Novack (2009). O uso de muitos atributos no processo de classificação pode aumentar a confusão entre classes, reduzindo a acurácia do resultado (JAIN *et al.*, 2000).

Desse modo, a mineração de dados selecionou apenas 5 atributos dos 27 inseridos no *software* WEKA 3.6. Assim, a árvore de decisão gerada utilizou apenas atributos texturais na separação entre as classes "Fragmento" e "Não-Floresta", o que indica, no caso específico deste trabalho, a maior importância da textura na classificação dos fragmentos florestais em relação aos atributos espectrais. Foram considerados relevantes, pela mineração de dados, os seguintes atributos texturais: Média da Banda 3 fusionada, Dissimilaridade da Banda 3 fusionada, Média da banda 4 fusionada, Dissimilaridade da Banda 4 fusionada e Dissimilaridade da Banda 5 fusionada.

Os processamentos aqui aplicados (restauração e fusão) foram fundamentais para a extração de atributos texturais bem definidos. A fusão de imagens foi a maior responsável no ganho de detalhes texturais. Portanto, tal procedimento pode potencializar a obtenção de melhores resultados, como em Novack *et al.* (2008).

```

B1 <= 20.4
| B9 <= 15.32
| | B1 <= 7
| | | B9 <= 5.16
| | | | B1 <= 3.6
| | | | | B9 <= 3.52: Não-Floresta (16.0/1.0)
| | | | | B9 > 3.52: Fragmento (7.0)
| | | | | B1 > 3.6: Não-Floresta (127.0)
| | | | B9 > 5.16
| | | | | B5 <= 5.04: Fragmento (1161.0)
| | | | | B5 > 5.04
| | | | | B9 <= 7.12: Não-Floresta (5.0)
| | | | | B9 > 7.12: Fragmento (20.0)
| | | B1 > 7
| | | | B1 <= 9.68
| | | | | B9 <= 9.48: Não-Floresta (212.0/1.0)
| | | | | B9 > 9.48: Fragmento (39.0)
| | | | | B1 > 9.68
| | | | | | B13 <= 7.32: Não-Floresta (2018.0/1.0)
| | | | | | B13 > 7.32
| | | | | | | B21 <= 5.68: Fragmento (4.0)
| | | | | | | B21 > 5.68: Não-Floresta (57.0/1.0)
| | | B9 > 15.32
| | | | B9 <= 18.88
| | | | | B1 <= 14.24: Fragmento (1269.0)
| | | | | B1 > 14.24: Não-Floresta (113.0)
| | | | B9 > 18.88: Fragmento (18079.0/3.0)
B1 > 20.4
| B1 <= 27.48
| | B9 <= 31.6: Não-Floresta (3809.0/2.0)
| | B9 > 31.6
| | | B9 <= 36.44
| | | | B13 <= 6.12: Não-Floresta (4.0)
| | | | B13 > 6.12: Fragmento (27.0)
| | | B9 > 36.44: Fragmento (632.0)
| | B1 > 27.48
| | | B9 <= 48.72
| | | | B1 <= 29.08
| | | | | B9 <= 30.44: Não-Floresta (1331.0)
| | | | | B9 > 30.44
| | | | | | B9 <= 34.8: Não-Floresta (19.0/1.0)
| | | | | | B9 > 34.8: Fragmento (6.0)
| | | | | B1 > 29.08: Não-Floresta (27095.0)
| | | B9 > 48.72
| | | | B1 <= 36.84: Fragmento (71.0)
| | | | B1 > 36.84: Não-Floresta (1398.0)

```

Onde:

B1 – Média da Banda 3 fusionada
B5 – Dissimilaridade da Banda 3 fusionada
B9 – Média da Banda 4 fusionada
B13 – Dissimilaridade da Banda 4 fusionada
B21 – Dissimilaridade da Banda 5 fusionada

Figura 5. A árvore de decisão gerada pela mineração de dados.

A classificação por árvore de decisão permitiu a obtenção de um mapa de fragmentos florestais no município de São José de Ubá (Figura 6). Nota-se que o município sofreu grande processo de fragmentação florestal, que pode ter sido causado pela expansão das atividades agropecuárias no Noroeste Fluminense (MOURA, 2005). As áreas florestais mais preservadas estão localizadas ao longo das margens dos cursos fluviais nos fundos de vale e em relevos com declive acentuado das fronteiras oeste e sul/sudeste do município (Figura 7). Pela classificação, verifica-se que a classe "Fragmento" ocupa 27,28% da área de São José de Ubá, enquanto que a classe "Não-Floresta" ocupa aproximadamente 72,72% da área municipal. Esse fato indica que a cobertura florestal é pequena, e, assim, recomenda-se que haja o desenvolvimento de políticas públicas ambientais para que se possa atenuar o problema.

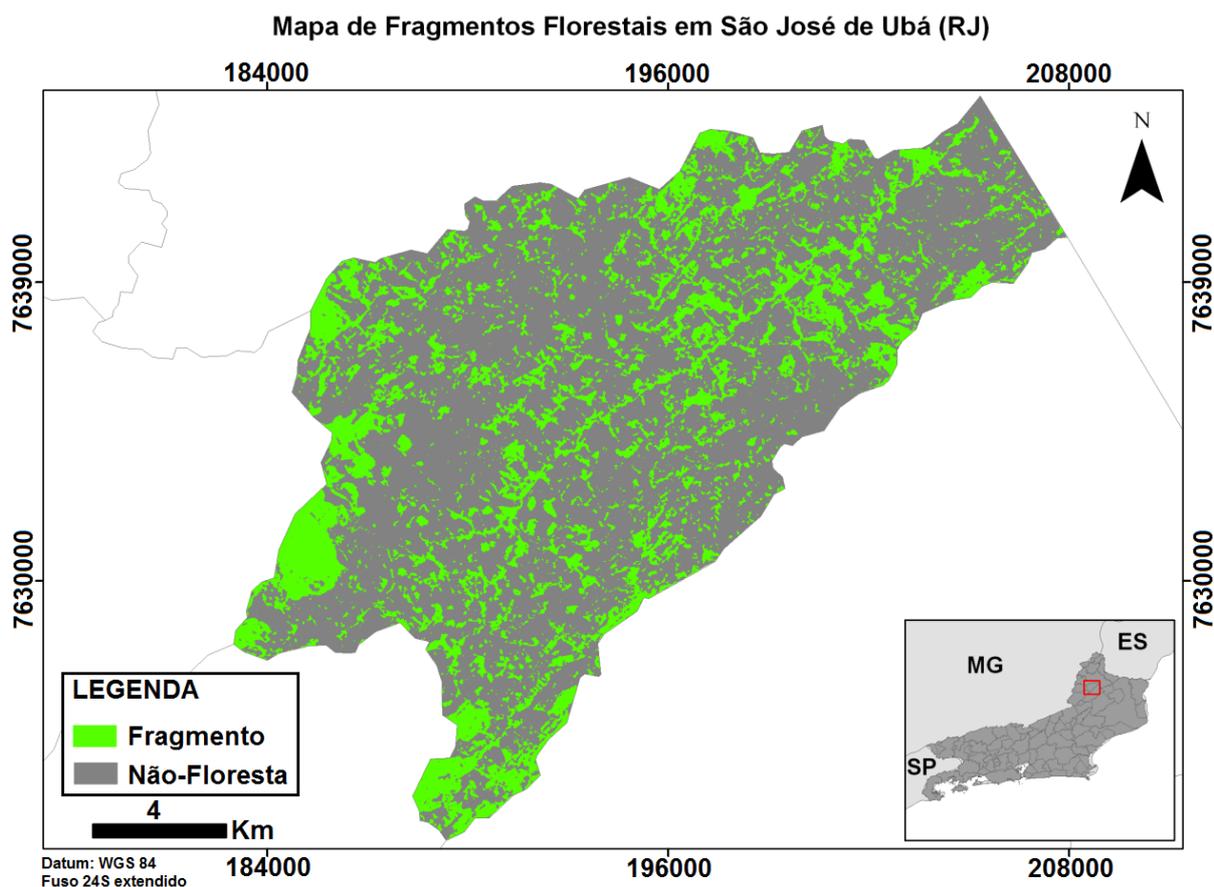


Figura 6. Mapa final de fragmentos florestais de São José de Ubá.

O mapa obtido apresentou índice Kappa de 0,765, que permite considerar essa classificação como sendo muito boa, de acordo com a escala de Landis e Koch (1977) na Tabela 1. Houve 133 acertos de 150 amostras, logo, a porcentagem do número de acertos foi de, aproximadamente, 89%. A matriz de confusão (Tabela 2) indica que dos 53 pontos amostrais da classe "Fragmento", 51 foram classificados corretamente, enquanto que apenas 2 foram classificados como "Não-Floresta". Dos 97 pontos amostrais da classe "Não-Floresta", 82 foram classificados corretamente e 15 foram classificados como "Fragmento". Estes resultados mostram a eficiência da metodologia utilizada.

Tabela 2. Matriz de confusão.

Classe	Fragmento	Não-Floresta
Fragmento	51	2
Não-Floresta	15	82

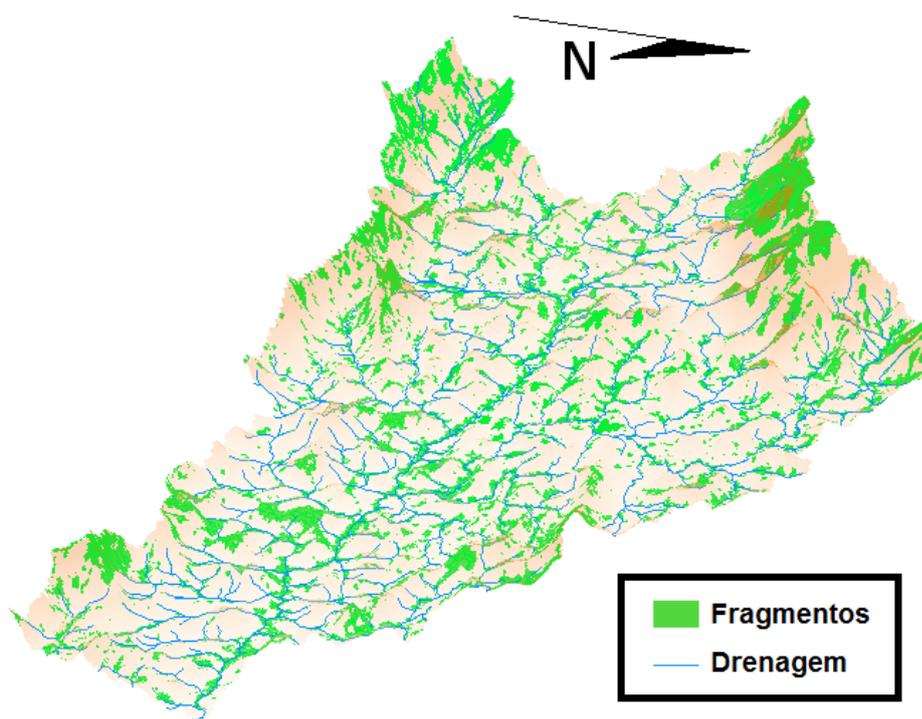


Figura 7. Percepção em 3D de São José de Ubá gerada a partir de um Modelo Digital de Elevação. Percebe-se que as áreas florestais mais bem preservadas estão em encostas declivosas e nos fundos de vale.

CONCLUSÃO

Foi possível confirmar a hipótese e cumprir o objetivo do trabalho. A metodologia desenvolvida, que envolve restauração, fusão IHS de imagens, mineração de dados e classificação de atributos texturais, permite a obtenção de resultados eficientes, mostrando que a metodologia utilizada foi eficaz para o mapeamento dos fragmentos florestais do município de São José de Ubá.

A aplicação da restauração de imagens foi útil na melhoria da definição das bordas dos fragmentos florestais, devido a um aumento na resolução espacial efetiva. A fusão IHS, como visto, combinou qualidade espectral de bandas multiespectrais com os detalhes espaciais de uma banda pancromática em um produto híbrido, que permitiu a extração de atributos texturais mais bem definidos.

A etapa de mineração de dados foi fundamental para reduzir a dimensionalidade dos dados e para classificar os fragmentos florestais com boa acurácia. Apenas 5 atributos texturais foram considerados, pela mineração de dados, como separadores entre as classes "Fragmento" e "Não-Floresta", e foram utilizados na geração da árvore de decisão pelo algoritmo C4.5, utilizada na classificação de imagens.

Finalmente, percebeu-se que a cobertura florestal de São José de Ubá está reduzida e fragmentada. Os resultados mostram que os dados de Sensoriamento Remoto e que o processamento digital de imagens podem ser utilizados como subsídio ao desenvolvimento de políticas públicas voltadas para a preservação do meio ambiente e manutenção da qualidade da paisagem, uma vez que a metodologia aqui apresentada é simples, rápida e não necessita de grandes intervenções humanas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMI, M.; DEPPE, F.; RIZZI, R.; MOREIRA, M. A.; RUDORFF, B. F. T.; FONSECA, L. M. G.; FARIAS, R. T. Fusão de imagens por IHS para melhorar a identificação de uso do solo em elementos amostrais. *Engenharia Agrícola*, v. 27, n. 2, p. 529-536, 2007.
- ANDERSON, L. O. A. **Classificação e monitoramento da cobertura vegetal de Mato Grosso utilizando dados multitemporais do sensor MODIS**. 2004. 247 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.
- ANGELO, N. P. **Aplicação de filtros de Gabor no processo de classificação de imagens digitais com base em atributos de textura**. 2000. 168p. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.
- ARAUJO, G. H. S.; ALMEIDA, J. R.; GUERRA, A. J. T. **Gestão Ambiental de Áreas Degradadas**. 4. ed. Rio de Janeiro: Bertrand Brasil, 2009.
- BOGGIONE, G. A. **Restauração de imagens do satélite Landsat-7**. 2003. 160 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.
- CÂMARA, G.; SOUZA, R.C.M.; FREITAS, U. M.; GARRIDO, J. SPRING: Integrating Remote Sensing and GIS by object-oriented data modelling. *Computers and Graphics*, v. 20, n. 3, p. 395-403.
- CARVALHO, L. A. S.; FONSECA, L. M. G.; NOVO, E. M. L. M.; OLIVEIRA, C. G. Um produto híbrido CBERS-2B para a identificação de fragmentos de vegetação arbórea. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba. *Anais...* São José dos Campos: INPE, 2011.
- CARVALHO, M. V. A. **Classificação da cobertura e uso do solo com imagens Worldview-2 utilizando mineração de dados e análise baseada em objetos**. 2011. 201 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.
- CECCHINI, A.; SERVA, S.; D'ORIO, M.; MOCCIA, A. Data fusion techniques for processing aerospace Remote Sensing electro-optical data. *Aerotecnia*, v. 89, n. 2, p. 76-89, 2011.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v.37, n.1, p.35-46, 1991.
- COURA, S. M. C. **Mapeamento de vegetação do estado de Minas Gerais utilizando dados MODIS**. 2006. 150 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.
- COURA, S. M. C.; SHIMABUKURO, Y. E.; FONSECA, L. M. G. Mapeamento da cobertura vegetal em escala regional do Estado de Minas Gerais utilizando imagens MODIS. *Boletim de Geografia Teórica*, v. 35, n. 3, p. 661-681, 2010.
- CUNHA, S. B.; GUERRA, A. J. T. Degradação ambiental. In: GUERRA, A. J.; CUNHA, S. B. (Org.). **Geomorfologia e meio ambiente**. 6. ed. Rio de Janeiro: Bertrand Brasil, 2006.
- FAYYAD, U.; PIATESKY-SHAPIRO, G.; SMYTH, P.; UTHURUSAMY, R. **Advances in knowledge discovery and Data mining**. Cambridge: MIT Press, 1996.
- QI, F.; ZHU, A. Knowledge Discovery from soil maps using inductive learning. *International Journal of Geographical Information Science*, v. 17, n. 8, p. 771-795, 2003.

- FERNANDES, P. J. F. **Geoprocessamento aplicado ao mapeamento de Áreas de Preservação Permanente em São José de Ubá-RJ**. 2010. 62 p. Trabalho de Conclusão de Curso (Graduação em Geografia) – Universidade Federal Fluminense, Niterói, 2010.
- FONSECA, L.M. G.; NAMIKAWA, L.; CASTEJON, E.; CARVALHO, L.; PINHO, C.; PAGAMISSE, A. Image fusion for Remote Sensing applications. In: ZHENG, Y (Ed.). **Image fusion and its applications**. 1. ed. Lorman: Alcorn State University, 2011.
- FONSECA, L. M. G.; PRASSAD, G. S. S. D.; MASCARENHAS, N. D. A. Combined interpolation-restoration of Landsat images through FIR filter design techniques. **International Journal of Remote Sensing**, v. 14, n. 13, p. 2547-2561, 1993.
- GUERRA, A. J. T. Processos Erosivos nas Encostas. In: GUERRA, A. J.; CUNHA, S. B. (Org.). **Geomorfologia: Uma atualização de bases e conceitos**. 7. ed. Rio de Janeiro: Bertrand Brasil, 2007.
- GREGGIO, T. C.; PISARRA, T. C. T.; RODRIGUES, F. M. Avaliação dos fragmentos florestais do município de Jaboaticabal-SP. **Revista Árvore**, v. 33, n. 1, p. 117-124, 2009.
- HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software: an update. **SIGKDD Explorations**, v. 11, n. 1, p. 10-18, 2009.
- HARALICK, R.M.; SHANMUGAM, K.; DINKSTEIN, I. Textural features for image classification. **IEEE transactions on systems, man and cybernetics**, v. 3, n. 6, p. 610-621, 1973.
- HSU, W.; LEE, L. M.; ZHANG, J. Image mining: trends and developments. **Journal of Intelligent Information Systems**, v. 19, n. 1, p. 7-23, 2002.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on pattern analysis and machine intelligence**, v. 22, N. 1, p. 4-37, 2000.
- KORTING, T. S.; FONSECA, L. M. G.; ESCADA, M. I. S.; SILVA, F. C.; SILVA, M. P. S. GeoDMA - a novel system for spatial Data mining. In: DATA MINING WORKSHOPS, 2008. ICDMW '08. IEEE INTERNATIONAL CONFERENCE, 2008, Pisa, Italy. **Proceedings...** Pisa: IEEE, 2008.
- LANDIS, J. R., KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, p.159-174, 1977.
- MCCROBERTS, R. E. Satellite image-based map: scientific inference or pretty pictures?. **Remote Sensing of Environment**, v. 115, n. 2, p. 715-724, 2011.
- MOURA, N. N. **Percepção de risco do uso de agrotóxicos: o caso dos produtores de São José de Ubá/RJ**. 2005. 92 p. Dissertação (Mestrado em Desenvolvimento, Agricultura e Sociedade) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2005.
- NOVACK, T. **Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor QuickBird**. 2009. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.
- NOVACK, T.; FONSECA, L.M.G.; KUX, H.J. Quantitative comparison of segmentation results from IKONOS images sharpened by different fusion and interpolation techniques. In: GEOBIA - Geo-Object Based Image Analysis Conference, 2008, Calgary, **Proceedings...** Calgary: GEOBIA, 2008.
- SHI, W.; ZHU, C.; TIAN, Y; NICHOL, J. Wavelet-based image fusion and quality assessment. **International Journal of Applied Earth Observation and Geoinformation**, v. 6, n. 3-4, p. 241-251, 2005.

- TU, T.; SU, S.; SHYU, H.; HUANG, P. S. Efficient intensity-hue-saturation-based image fusion with saturation compensation. **Optical Engineering**, v. 40, n. 5, p. 720-728, 2001.
- VIEIRA, M. A. **Análise de imagem orientada a objeto e mineração de dados aplicadas ao mapeamento da cultura da cana-de-açúcar**. 2010. 110 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.
- VIEIRA, M.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object based image analysis and data mining applied to a remotely sensed Landsat time-series to map sugarcane over large áreas. **Remote Sensing of Environment**, v.123, p. 533-562, 2012.
- WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: practical machine learning tools and techniques**. 3. ed. Burlington: Morgan Kaufmann, 2011.