

## **Análise de textura de imagem de alta resolução para aprimorar a acurácia da classificação da mata atlântica no sul da Bahia**

Priscila Gonçalves Couto Sette<sup>1</sup>  
Philippe Maillard<sup>2</sup>

<sup>1</sup> Universidade Federal de Minas Gerais – UFMG  
Instituto de Geociências – ICG  
Av. Antônio Carlos, 6627 – Belo Horizonte - MG  
Priscila.sette@yahoo.com.br  
Philippe@ufmg.br

**Abstract.** The Atlantic Forest is a Brazilian biome of great importance that has suffered repeated degradation over the years. In the study and monitoring of this biome several classification methodologies and analyses through remote sensing have been investigated. In this study grey levels matrix of co-occurrence were used as a texture analysis approach. This tool was used as a means to improve classification accuracy over spectral classification and has yielded good results. For this purpose three successional stages of *Floresta Ombrófila Densa* from Atlantic Forest were sampled in the field. The spectral visible bands (red, green and blue) from the high resolution satellite FORMOSAT 2 were used to compute texture features. The textural measurements used were contrast, entropy, correlation, inverse differential moment and angular second moment. The classification using only the visible bands of the high resolution image yielded a 46,7% accuracy while adding the texture features provided an accuracy of 83,9%, showing a good improvement. The knock-out method was used for the analysis of the contribution of the textural bands in the classification accuracy showing that the angular second moment and correlation bands were sufficient to improve the accuracy (85%) without any significant increase in processing complexity.

**Palavras-chave:** remote sensing, classification, texture, GLCM, Atlantic Forest, sensoriamento remoto, classificação, matriz de co-ocorrência, Mata Atlântica.

### **1. Introdução**

A classificação com uso do sensoriamento remoto, utilizando feições espectrais, ainda depende da experiência do usuário para ter uma boa confiabilidade em termos de acurácia. Para aprimorar a precisão da classificação, feições não espectrais podem ser incorporadas (Mather, 2004). A textura é um tipo de feição não espectral que se mostrou eficaz para melhorar a acurácia da classificação em relação à classificação que utiliza somente informações espectrais nas aplicações florestais (Franklin, 2001). Tradicionalmente, quando é realizada a classificação de uma imagem, apenas os tons de cinza são analisados e não tira vantagem do conteúdo contextual das imagens como faria o foto interprete. A análise de textura visual é uma das maneiras de levar em conta o contexto no qual cada pixel é inserido. Quando métodos de realce da textura de imagens são utilizados, as feições de textura resultantes podem ser adicionadas ao processo de classificação, melhorando assim a acurácia (Hay, 1993). A imagem de alta resolução é mais uma ferramenta que permite aprimorar a acurácia da classificação que utiliza somente parâmetros espectrais. Métodos de análise de textura visual são especialmente úteis com imagens de alta resolução de áreas florestais, pois nestas imagens, o tamanho do pixel é muitas vezes menor que uma árvore de tamanho médio.

A área de estudo é uma região de Mata Atlântica localizada no Sul da Bahia, na Costa do Descobrimento, nos municípios de Belmonte, Santa Cruz Cabrália e Porto Seguro. Neste trabalho são analisadas as áreas de Floresta Secundária no domínio da Floresta Ombrófila Densa, nos estágios avançado, médio e inicial de regeneração.

Os fragmentos florestais remanescentes da região encontram-se em sua maioria nos vales, em áreas de preservação permanente ou em áreas de reserva legal de propriedades privadas. O estudo desta vegetação remanescente, que sofreu pressão por conta de madeireiros e fazendeiros ao longo dos anos, é importante para a conservação destes. Esta área foi escolhida

por ainda preservar, apesar da grande devastação ocorrida no passado, grandes fragmentos vegetais. Este estudo e a metodologia deste trabalho poderá ser utilizada para o monitoramento e levantamentos mais detalhados da evolução dos estágios sucessionais através dos parâmetros alométricos para trabalhos de conservação da vegetação da região, como a proposição de corredores ecológicos para interligação dos fragmentos florestais da região.

Para a análise da vegetação em campo foram georreferenciadas e classificadas as unidades amostrais nos diferentes estágios sucessionais. Assim parâmetros de campo foram escolhidos para obtenção de uma estimativa mais precisa em termos de estágios sucessionais da Floresta Atlântica.

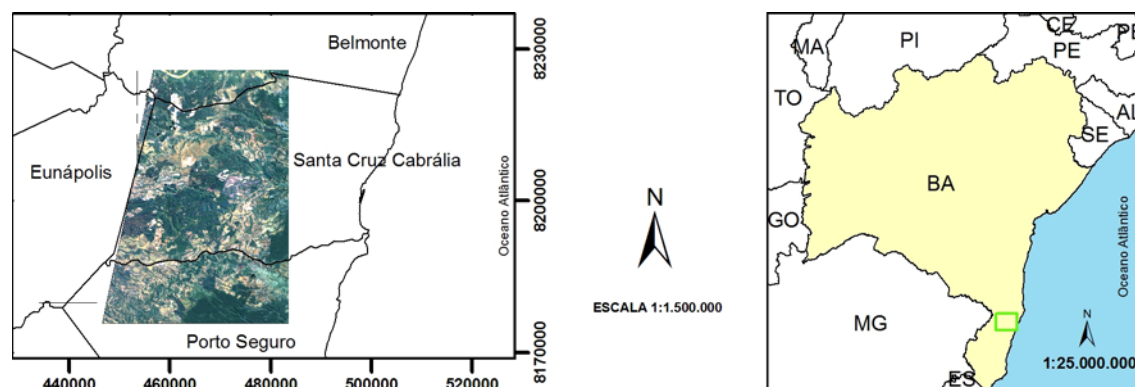
A imagem de alta resolução utilizada neste trabalho é do satélite FORMOSAT. Suas imagens possuem dois metros de resolução espacial no modo pancromático e oito metros no modo multiespectral.

O método de extração das feições de textura utilizado é a matriz de co-ocorrência dos níveis de cinza (GLCM – Grey levels co occurrence matrix). Este método tem se mostrado especialmente eficaz para a análise de vegetação (Kayitakire *et al.*, 2006; Maillard, 2003; Lock e Kirchner, 1997). O objetivo do trabalho consiste em determinar a contribuição das feições de textura geradas a partir das matrizes de co-ocorrência no aprimoramento da acurácia da classificação dos estágios sucessionais da vegetação de mata atlântica.

## 2. Metodologia de Trabalho

### 2.1. Área de Estudo

A Mata Atlântica do Sul da Bahia, no domínio da Floresta Ombrófila Densa, nos municípios de Belmonte, Santa Cruz Cabralia e Porto Seguro, compõe a área de estudo deste trabalho (Figura 1).



**Figura 1** – Localização da cena de alta resolução no contexto dos municípios do sul da Bahia.

Toda região estudada está localizada dentro do domínio da denominada Floresta Ombrófila Densa, conforme nova classificação da vegetação brasileira, adaptada a um sistema universal (IBGE, 1991), existindo a presença de ecossistemas associados à mata atlântica, neste caso, restingas e brejos. A floresta ombrófila densa regional está associada aos fatores climáticos de altas temperaturas (médias acima de 20° C), alta umidade do ar (média superior a 80%) e altos índices pluviométricos, bem distribuídos durante o ano, não apresentando déficit hídrico (período seco). Segundo a classificação de Koeppen, o clima presente na região é do tipo Af (quente e úmido, sem estação seca).

A floresta atlântica da região do extremo sul da Bahia se destaca como um núcleo de alta diversidade onde as condições climáticas (alta umidade e chuvas bem distribuídas) somadas à presença de elementos da flora e da fauna da floresta atlântica e da amazônica

(contatos existentes no passado) fizeram desta região uma das áreas de maior biodiversidade do planeta (Almeida, 2000).

Hoje segundo informações da Diretoria de Desenvolvimento Florestal da Bahia - DDF (1999), a cobertura florestal do extremo sul representa 11,4 % da área total, representada por fragmentos de floresta secundária em estágio inicial, médio e avançado de regeneração de mata atlântica, além de poucos fragmentos em estágio primário. Para o estado da Bahia a área remanescente da cobertura original de Mata Atlântica do estado em dados de 2008 é de 8,38% (SOS Mata Atlântica, 2008).

Para fins de mapeamento a floresta ombrófila densa é dividida em floresta primária e floresta secundária, conforme definições da resolução do Conselho Nacional de Meio Ambiente, CONAMA 005/94, sendo que neste estudo somente as áreas de floresta secundária foram analisadas.

## 2.2. Materiais

Neste trabalho foi utilizado um mosaico composto por um corte de 04 cenas do satélite FORMOSAT-2 de 2007, focando uma região com muitos fragmentos florestais remanescentes e a data de coleta da imagem é de 2007. O mosaico é composto por 3 bandas, vermelho (0,63 – 0,69  $\mu\text{m}$ ), verde (0,52 – 0,60  $\mu\text{m}$ ) e azul (0,45 – 0,52  $\mu\text{m}$ ). No processamento da imagem cedida foi realizado um fusão com a cena pancromática para obtenção da resolução espacial de 2 metros.

Foram levantados em campo a localização de unidades amostrais em cada um dos estágios sucessionais de Floresta Ombrófila Densa presentes na área de estudo para a amostragem de treinamento e de teste da classificação.

Foram amostradas 08 parcelas em estágio inicial de regeneração, 28 em estágio médio e 13 em estágio avançado, de acordo com o número de fragmentos de cada estágio sucessional encontrados na área de estudo.

Para a classificação da vegetação e enquadramento nos estágios sucessionais foi utilizada a Resolução CONAMA 005/94, que define as características dos diferentes estágios sucessionais de Mata Atlântica na Bahia. Para caracterização botânica da vegetação foi utilizado o sistema de classificação botânica das espécies de Cronquist (1981). Foram também coletados dados estruturais nas parcelas.

Os dados coletados em campo foram CAP (circunferência à altura do peito), altura total e espécie, para todas as árvores com CAP maior que 15,7 centímetros.

## 2.3. Métodos

O método escolhido neste trabalho para a extração das feições de textura foi a matriz de co-ocorrência dos níveis de cinza, GLCM em inglês. Este algoritmo, proposto por Haralick et al. em 1973, é um dos mais comuns e usados para a medição de textura de imagens óticas.

A textura pode ser caracterizada pela a distribuição espacial e a dependência espacial entre os tons de cinza em uma área (Haralick, 1979). A matriz de co-ocorrência consiste em um histograma de segunda ordem onde cada entrada relata a probabilidade conjunta de encontrar os níveis de cinza a uma certa distância e direção de cada um em uma janela pré-definida (Maillard, 2001). O método da matriz de co-ocorrência é principalmente uma técnica onde a variância espectral interna dos pixels de uma vizinhança é considerada como uma fonte valiosa de informação espacial (Hay, 1993).

A análise espacial de textura através da matriz de co-ocorrência requer que o usuário identifique cinco diferentes variáveis de controle: tamanho da janela; medidas de textura; banda a ser utilizada; nível de quantização e o componente espacial, que é a distância entre pixels e o ângulo (Franklin et al., 2001, Hay et al., 1996).

A definição do tamanho da janela foi realizada com base no tamanho das parcelas marcadas em campo e com a variação das áreas dos diferentes estágios sucessionais encontrados dentro dos fragmentos florestais existentes na área de estudo. Foram realizados testes, não apresentados aqui, com os tamanhos de janela de 16 x 16, 25 x 25 e 32 x 32 pixels. O tamanho de 25 x 25 pixels foi o que melhor explicou os três estágios sucessionais de Floresta Ombrófila Densa.

A imagem foi processada utilizando a banda verde, em tons de cinza, com nível de quantização de 32 níveis de cinza (5 bits). Dentre as bandas da imagem trabalhada, a banda verde é a que se mostra mais eficiente para a análise de vegetação. Isto ocorre devido à assinatura espectral das folhas, a aparência verde da folha e da vegetação, está relacionada a uma maior reflectância na banda verde, em relação às bandas azul e vermelha.

As direções/distâncias utilizadas para análise das medidas de textura em cada matriz foi de (3,3). Foram testadas as direções (0,3), (3,0), (2,2), (3,3), (4,4) e (5,5) e análise dos dados, através dos testes estatísticos de ANOVA e teste F, não apresentados aqui, correlacionados com os parâmetros de campo mostraram que a direção 3,3 foi a que melhor correlacionou as feições de textura com os parâmetros de campo dos três estágios sucessionais. As medidas de textura analisadas foram o segundo momento angular, o contraste, a correlação, a entropia, a homogeneidade ou momento diferencial inverso.

As Equações 1 a 5 para o cálculo de cada uma das cinco feições utilizadas são apresentadas abaixo.

$$ASM = \sum_i \sum_j \{p(i,j)\}^2 \quad (1)$$

$$CONTRASTE = \sum_{n=0}^{N_p-1} n^2 \left\{ \sum_{i=1}^{N_p} \sum_{j=1}^{N_p} p(i,j) \right\}_{|i-j|=n} \quad (2)$$

$$CORRELAÇÃO = \frac{\sum_i \sum_j (i,j) p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

Onde:  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x$  e  $\sigma_y$  são as médias e desvios padrão de  $p_x$  e  $p_y$ .

$$IDM = \sum_i \sum_j \frac{1}{1 + (i-j)^2} p(i,j) \quad (4)$$

$$ENTROPIA = - \sum_i \sum_j p(i,j) \log(p(i,j)) \quad (5)$$

Primeiramente foi realizada a classificação da imagem multiespectral (sem feições texturais) da área de estudo. A Classificação Supervisionada foi escolhida, pois este método é baseado em um conhecimento prévio da área. Metade das parcelas coletadas em campo foram utilizadas como amostras de treinamento, a outra metade serviu para amostras de teste (controle).

O algoritmo utilizado para a classificação supervisionada foi o algoritmo Máxima Verossimilhança, ou MAXVER. Este algoritmo é um dos mais utilizados para a classificação supervisionada. Para a avaliação da classificação da imagem foi utilizada a matriz de confusão (ou matriz de contingência) e o índice kappa. O coeficiente kappa, resume a informação dada pela matriz de confusão. O valor do coeficiente kappa é obtido a partir da fórmula:  $k = P_o - P_e / (1 - P_e)$ , onde  $P_o$  = proporção global de concordância observada e  $P_e$  = proporção global de concordância esperada ao acaso. Para valores próximos a 1, ou próximos de 100% (índice kappa), mostram coerência entre os dados de entrada e a classificação final. Metade das parcelas foram utilizadas como amostras de teste para a avaliação da acurácia.

Após a classificação da imagem multiespectral a classificação utilizando as medidas textura foi realizada. Cada uma das medidas, entropia, correlação, momento diferencial inverso, segundo momento angular, energia e contraste, foram utilizadas como uma banda da imagem. A fim de determinar a contribuição real das bandas e feições de textura, o algoritmo “knock-out” foi utilizado para a determinação de quais medidas textura foram mais produtivas na classificação. O método “knock-out” serve pra eliminar progressivamente as feições menos úteis e melhorar a eficiência computacional da classificação, uma vez que a adição de todas as feições de textura podem não contribuir de modo significativo a aumentar a acurácia, mas sim de modo a perder a eficiência processual. Este método foi desenvolvido por Sambur (1975), onde para N feições, é realizada todas as possíveis classificações usando N – 1 feições e rejeita a feição que não obteve o melhor resultado. O algoritmo então realiza o procedimento com N – 2, N – 3, ..., N – (N – 1), até que todas as feições gerem um ranking de performance. O número total de classificações é então reduzido de forma a tornar-se  $N*(N+1)/2$ .

### 3. Resultados e Discussão

A classificação supervisionada com o algoritmo Máxima Verossimilhança foi feita com a imagem nas bandas vermelho, verde e azul obtendo percentuais de acurácia de 46,7%, para os valores de kappa das amostras de teste. Outra imagem com mais cinco bandas de textura (momento diferencial inverso, segundo momento angular, correlação, contraste e entropia) foi produzida. Quando realizada a classificação com as três bandas da imagem mais 5 bandas de textura houve um aumento da acurácia de 37,1%, chegando a 83,8% de acurácia da classificação. A classificação utilizando somente as bandas de textura também foi realizada chegando a um percentual de acurácia de 55,6%. Demonstrou-se, portanto a melhora da acurácia da classificação quando utilizado bandas com feições espectrais e bandas com feições não espectrais. O resultado de todas as classificações processadas, com as amostras de treinamento e teste, e os respectivos testes kappa, podem ser observadas na Tabela 1.

O método “knock-out” foi utilizado para verificar quais as bandas de textura foram mais eficientes para aprimorar a acurácia da classificação e eliminar as bandas que menos contribuíram. A banda de feição de textura que menos contribuiu para a melhora da acurácia da classificação foi o contraste. As feições segundo momento angular e correlação obtiveram melhor desempenho de acordo com o método knock-out.

No primeiro passo foi realizada a classificação com todas as combinações entre bandas excluindo uma. Os resultados mostraram que a banda contraste (CONT) teve o pior comportamento nas classificações, portanto foi excluída para o segundo passo do método. No segundo passo foi realizado o mesmo procedimento, realizando a classificação com as bandas restantes menos uma. De acordo com os resultados as bandas momento diferencial inverso (IDM) e entropia (ENT) tiveram pior desempenho na classificação. Foi então realizado a classificação com as bandas segundo momento angular (ASM) e correlação (COR) juntamente com as bandas espectrais, vermelho (R), verde (G) e azul (B) e obteve a acurácia de 90,9% para as amostras de treinamento, com 88,4% de kappa e 88,3% para as amostras de teste com 85% de kappa.

Tabela 1 – Classificação com bandas espectrais e não espectrais de textura, onde: RGB – Vermelho, Verde, Azul, IDM – momento diferencial inverso, ASM – segundo momento angular, COR – correlação, CON – contraste, ENT – entropia.

BANDAS	TREINAMENTO (%)	KAPPA (%)	TESTE (%)	KAPPA (%)
RGB	60,5	52,8	54,5	46,7
G	51,0	40,5	49,0	37,5
RGB + TODAS TEXTURAS	91,0	88,6	87,3	83,8
RGB + IDM	89,0	86,1	87,2	83,7
RGB + ASM	89,5	86,7	87,2	83,6
RGB + COR	88,5	85,3	87,2	83,6
RGB + CON	88,6	85,5	86,2	82,4
RGB + ENT	89,3	86,4	87,6	84,2
TODAS TEXTURAS	76,5	70,2	65,1	55,6

O valor obtido na acurácia da classificação com as três bandas espectrais e as duas de textura para o valor de kappa das amostras de teste foi maior em termos de eficiência, 85% contra 83,9%, da classificação com três bandas espectrais e cinco de textura, além de ter realizado a classificação com menor tempo de processamento dos dados.

A imagem final de classificação com as bandas espectrais vermelho, verde e azul e com as bandas de textura, segundo momento angular e correlação é apresentada na Figura 2. Na apresentação foi dado destaque para as classes de interesse deste estudo.

#### 4. Conclusões

A classificação da área de estudo mostrou uma acurácia alta para os valores de kappa das amostras de teste de 83,9% quando aliadas as feições espectrais e as feições de textura. Mostrando uma melhora na acurácia em relação à classificação espectral (46,7%) e a classificação somente com o uso das feições de textura (55,6%). O uso da imagem de alta resolução contribuiu para a acurácia da classificação. A utilização do método de knock out também foi importante para a escolha das bandas de textura que realmente contribuíram para a melhora da acurácia da classificação na área de estudo resultando na redução do tempo de processamento dos dados, apesar da utilização de somente duas bandas de textura com as bandas espectrais.

Espera-se que a metodologia de classificação e de predição de dados estruturais possa contribuir de forma significativa para o estudo espacial dos fragmentos florestais e também para o estudo dos detalhes de cada um deles em termos da estrutura horizontal e vertical dos indivíduos e de diferenciação dos estágios sucessionais, contribuindo para o monitoramento de áreas, estudos de formação de corredores e mini corredores ecológicos, projetos de restauração florestal, ampliação de unidades de conservação, entre outros, através do detalhamento da representatividade de cada um dos fragmentos florestais encontrados nas áreas de interesse.

É importante também que a metodologia possui fácil replicabilidade para outras áreas de estudo podendo proporcionar esse maior detalhamento nos estudos de vegetação.

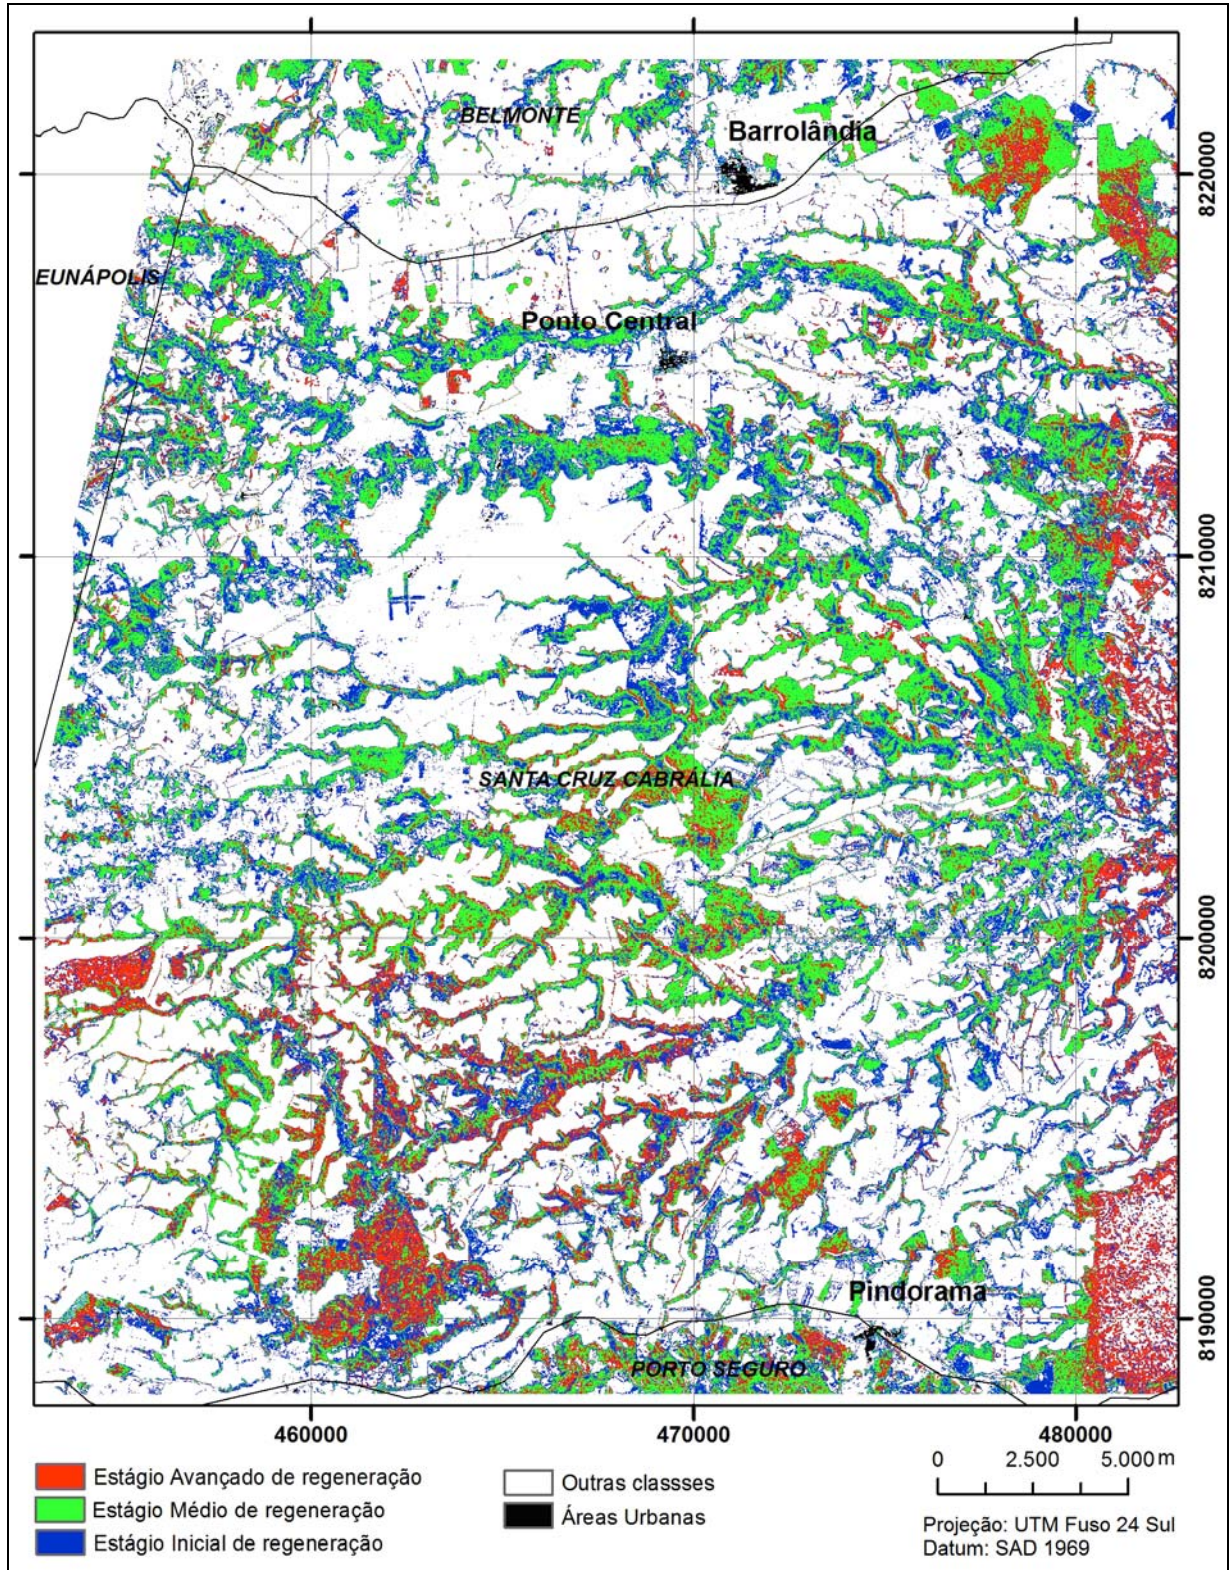


Figura 2 – Classificação da imagem final com cinco bandas (vermelho, verde, azul, segundo momento angular, correlação).

## 5. Referências Bibliográficas

- Almeida, D. S. (2000). *Recuperação Ambiental da Mata Atlântica* (1st ed.). Editus, Ilhéus, BA.
- SOS MATA ATLÂNTICA (2008). *Atlas dos Remanescentes Florestais de Mata Atlântica* (1st ed.).
- CONAMA (1994). *Resolução nº 005/94*.
- Cronquist, A. (1981). *An integrated system of classification on flowering plants* (1st ed.). Columbia University Press, New York, NY.
- DDF (1999). *Mapa dos remanescentes florestais do estado da Bahia* (1st ed.). DDF, Salvador.
- Franklin, S. E., A. J. Maudie, e M. B. Lavigne (2001). Using spatial cooccurrence texture to increase forest structure and species composition classification accuracy. *Photogrammetric Engineering and Remote Sensing* 67(7), 849–855.
- Haralick, R. M. (1979). Statistical and structural approaches to texture. *Proceedings of The IEEE* 67(5), 786–804.
- Haralick, R. M., K. Shanmugam, e I. Dinstein (1973a). Textural features for image classification. *IEEE Trans. Sys. Man Cybern* 3, 610–621.
- Haralick, R. M., K. Shanmugam, e I. Dinstein (1973b). Textural features for image classification. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS* 3(6), 610–621.
- Hay, G. J. (1993). *Visualizing 3-D texture: A Three dimensional Structural Approach to Model forest Texture*. Master Thesis, University of Victoria, Canada.
- Hay, G. J., K. Niemann, e G. McLean (1996). An object-specific image-texture analysis of h-resolution forest imagery. *Remote Sensing of Environment* 55, 108–122.
- IBGE (1991). *Classificação da Vegetação Brasileira, Adaptada a um Sistema Universal* (1st ed.). IBGE, Rio de Janeiro.
- Kayitakire, F., C. Hamel, e P. Defourny (2006). Retrieving forest structure variables based on image texture analysis and ikonos-2 imagery. *Remote Sensing of Environment* 102, 390–401.
- Lock, R. E. M. e F. F. Kirchner (1997). Classificação de imagens multiespectrais de landsat tm e feições de textura: mapeamento da cobertura da terra. *Floresta* 27(12), 41–58.
- Maillard, P. (2001). *Texture in High Resolution Digital Images of the Earth (Ph.D. dissertation)*. Brisbane, Australia: 348, p.
- Maillard, P. (2003). Comparing texture analysis methods through classification. *Photogrammetric Engineering and Remote Sensing* 69(4), 357–367.
- Mather, P. M. (2004). *Computer Processing of remotely-sensed images: an introduction* (3rd ed.). John Wiley and Sons, London.
- Sambur, M. R. (1975). Selection of accoustic features for speaker identification. *IEEE Transactions on Accoustical Speech Signal Processing* 23, 176–182.