

Análise e classificação textural de áreas de mata e café na região de Machado - MG

Vanessa Cristina Oliveira de Souza¹
Tatiana Grossi Chquiloff Vieira^{1,2}
Helena Maria Ramos Alves^{1,3}
Margarete Marin Lordelo Volpato^{1,2}

¹ Empresa de Pesquisa Agropecuária de Minas Gerais – EPAMIG/CTSM
Caixa Postal 176 - 37200-000 – Campus da UFLA - Lavras - MG, Brasil
{vanessa,tatiana,helena,margarete}@epamig.ufla.br

² Bolsista FAPEMIG

³ Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA/CAFÉ

Abstract. Automatic classification of satellite images to map coffee lands has not produced good results. This type of mapping is still done mainly by visual interpretation, which requires longer processing periods and working hours on the part of the interpreter. In the case of coffee, visual mapping is more used due to the spectral overlap between coffee and forest land cover types. As the texture of these two targets is largely used by the interpreter for the visual classification of these land cover types, the objective of this work was to study the textural patterns of coffee and forest and to classify them using the Texture software classifier. Testing was carried out on TM Landsat 5 images, bands 3 and 4. The best results were obtained using cluster shade measurement, with 256 grey levels and windows of 3 x 3 pixels. With these parameters a kappa of 86% was obtained, which confirms that texture measurements can be used successfully in automatic mapping of coffee lands.

Palavras-chave: automatic image classification, textural analysis, coffee, mapping, classificação automática de imagens, análise textural, café, mapeamento

1. Introdução

No Brasil, o zoneamento agrícola e monitoramento do café têm sido preocupações constantes, dada a importância dessa cultura no cenário nacional. Minas Gerais se destaca entre os demais estados da federação em área plantada e quantidade produzida do café, especialmente na região sul do Estado.

Estudos empregando imagens de satélite para o mapeamento de áreas agrícolas brasileiras foram realizados em diferentes culturas. Os estudos demonstraram o potencial desses dados. Segundo Medeiros *et al.* (1996), novas técnicas e metodologias de mapeamento são evidenciadas, experimentadas e adotadas, a fim de agilizar processos de tomada de decisão, minimizar e racionalizar custos operacionais e, concomitantemente, fornecer informações cada vez mais confiáveis num menor espaço de tempo.

A cultura cafeeira tem sido mapeada com sucesso por diversos pesquisadores, como Dallemand *et al.* (1987) e Batista *et al.* (1990). Especificamente em Minas Gerais, Tardin *et al.* (1992), Moreira *et al.* (2004), Vieira *et al.* (2007a) e Vieira *et al.* (2007b) têm obtido bons resultados no mapeamento e caracterização da cultura cafeeira na região. Moreira (2007) mapeou todo o estado de Minas Gerais, classificando visualmente imagens de sensoriamento remoto.

A classificação de imagens digitais pode ser feita automática ou visualmente. Na abordagem automática, após as imagens serem segmentadas, um algoritmo é aplicado e, de acordo com medidas estatísticas, os polígonos vão sendo classificados. Na abordagem visual, um especialista, utilizando uma imagem segmentada, ou não, e classifica os polígonos de acordo com seu conhecimento sobre os alvos a serem mapeados.

Para mapear o café, classificadores automáticos são raramente usados. Isso porque a resposta espectral dessa cultura é bastante complexa, em função das diversas variáveis que envolvem a caracterização da mesma e do ambiente em que está inserida (Vieira *et al.*, 2006). Além disso, sua resposta espectral assemelha-se muito com a da mata nativa. O trabalho de Bernardes *et al.* (2007) demonstra que, numa região de relevo mais acentuado, o melhor índice kappa alcançado com classificação automática é de 38%, utilizando o classificador Battacharya.

Os classificadores automáticos de imagens digitais convencionais utilizam apenas a resposta espectral da imagem, por meio de medidas estatísticas de primeiro grau. Como as curvas espectrais da mata e do café são muito parecidas, é comum e esperada tal confusão entre essas duas classes. Por outro lado, o que mais diferencia visualmente uma área de mata, de uma ocupada com café é a textura das imagens (Figura 1).

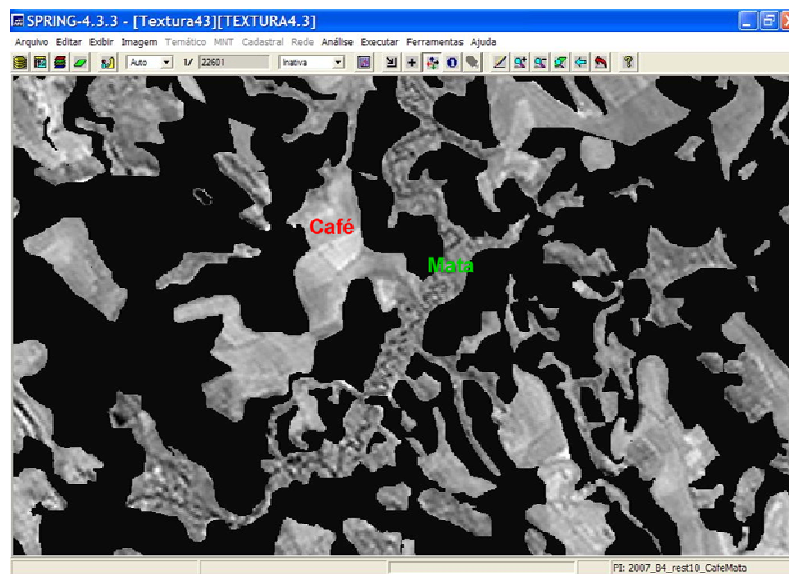


Figura 1. Imagem do satélite Landsat 5, banda 4, demonstrando a diferença de textura entre uma área de mata e uma de café.

Textura é um conceito intuitivo que descreve suavidade, rugosidade e regularidade da região (Haralick *et al.*, 1973). É uma das características mais importantes para classificar e reconhecer objetos, e pode ser caracterizada por variações locais em valores de *pixels* (níveis de cinza) que se repetem de maneira regular ou aleatória ao longo do objeto ou imagens. Pode ser definida ainda, como efeito visual que é produzido pela distribuição espacial de variações de tonalidade (Fernandes, 2005).

Para medir as características texturais de um objeto, Haralick *et al.* (1973) propuseram a matriz de co-ocorrência dos níveis de cinza, a qual é uma tabulação de diferentes combinações de valores de intensidade dos *pixels* que ocorrem em uma imagem. Eles ainda definiram 14 medidas texturais que derivam da matriz de co-ocorrência. Em 1984, Connors *et al.* (1984) descreveram outras duas medidas chamadas *Cluster Shade* e *Cluster Prominence*. Essas medidas podem caracterizar o conteúdo de uma imagem.

Gerar a matriz de co-ocorrência tem um alto custo computacional, por isso, em 1990, Welch *et al.* (1990) propuseram um novo método, que extrai textura a partir de vetores de soma e de diferença dos níveis de cinza. Deste trabalho surgiram mais nove medidas (Fernandes, 2005).

O objetivo desse trabalho é usar medidas texturais para classificar áreas de mata e café utilizando imagens do satélite Landsat 5.

2. Área de Estudo

A área de estudo foi na região do município de Machado, no Sul de Minas Gerais. A área encontra-se entre as coordenadas s 21°42'5.48" e s 21°31'10.06" e o 45°47'30.23" e o 46°2'38.68" (Figura 2). A região foi escolhida por abranger tanto um área de relevo acidentado, quanto uma área de relevo plano, localiza mais a nordeste da região. O relevo acidentado é importante, pois é sabido que os classificadores automáticos convencionais comportam-se melhor em relevos planos, devido a problemas causados pela sombra, interferindo na resposta espectral do dossel do cafeeiro.

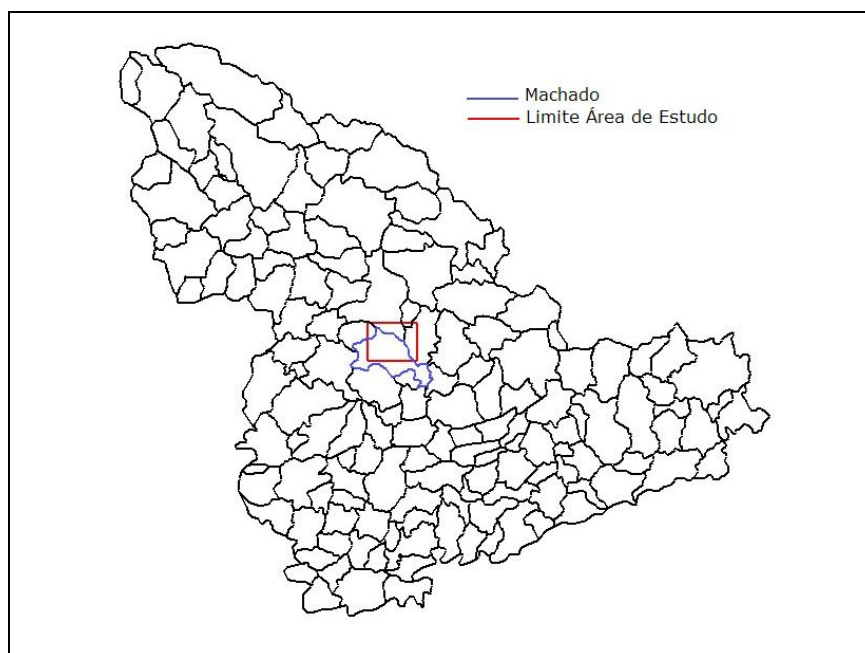


Figura 2. Área de estudo, região Sul de Minas Gerais.

3. Material e Métodos

No presente trabalho foram utilizadas imagens das bandas 3 (0,63 - 0,69 μm), 4 (0,76 - 0,90 μm) e 5 (1,55 - 1,75 μm) do satélite Landsat 5, de 16/08/2007, órbita ponto 219/75, sensor TM, com resolução espacial de 30 metros, restaurada para 10 metros. Os *softwares* utilizados foram o Texture (Rennó *et al.*, 1998) e o SPRING (Câmara *et al.*, 1996).

O Texture implementa as medidas de extração de textura de Haralick, as baseadas em vetor soma e vetor diferença e também *cluster shade* e *cluster prominence*.

No SPRING, foi gerado visualmente o mapa de uso da terra da região, baseado no conhecimento dos interpretadores e em mapas anteriores. O mapa foi conferido em campo e reajustado. As bandas 3 e 4 foram escolhidas por serem as bandas do satélite que mais refletem a vegetação. Sendo assim, são as bandas que possuem a maior quantidade de informação que interessa nesse trabalho. Essa informação é corroborada por Vieira *et al.* (2006).

O mapa de uso final foi utilizado como máscara das imagens a serem classificadas automaticamente. Apenas os polígonos classificados como mata ou café entraram na classificação automática. Isso foi feito porque o intuito do trabalho era descobrir a resposta textural das feições de café e mata, e não de outros alvos contidos na imagem. Os polígonos que eram mata e café foram então exportados do SPRING para o Texture. Alguns foram escolhidos para o treinamento do classificador.

Para classificar uma imagem no Texture, é preciso definir o conjunto de medidas, a quantização do nível de cinza e o tamanho, em *pixels*, da janela. A classificação foi feita sobre

os polígonos exportados do SPRING, a imagem mascarada e o algoritmo de classificação padrão. Ou seja, os polígonos já classificados visualmente é que foram classificados pelo Texture.

Todas as possibilidades de combinação entre as variáveis banda, quantização e tamanho de janela foram testadas. A priori, escolheu-se todas as medidas implementadas pelo Texture. Os valores médios das medidas, para cada classe, de algumas dessas combinações, podem ser vistos nas Tabelas 1, 2, 3 e 4. Excluiu-se dessas tabelas as medidas pouco significativas. Com isso, foi possível verificar os valores das medidas para as diferentes classes.

4. Resultados e Discussão

A partir dos testes, chegou-se a conclusão de que a quantização de 256 níveis de cinza, na banda 4, com janelas de 3x3 *pixels* causa uma maior separabilidade entre as classes de café e mata. As melhores medidas obtidas foram a *cluster shade* e a variância do vetor soma.

O *cluster shade* mede a falta de simetria numa imagem. Quando os valores são altos, a imagem é não simétrica, ou seja, possui muita rugosidade. Áreas cobertas com mata possuem essa característica muito mais acentuada do que áreas cafeeiras. Isso porque os indivíduos arbóreos que compõe o dossel possuem diversidade de espécies, tamanhos e de formato da copa. Esses parâmetros causam também uma maior quantidade de sombra, o que dá a imagem essa aparência mais rugosa. A variância do vetor soma também relaciona-se a rugosidade. Quanto maior o valor dessa medida, mais rugosa a feição.

Os resultados com as bandas 3 e 5 foram sempre inferiores aos com a banda 4. Esse resultado já era esperado, visto que a banda 4 afere uma maior reflectância da vegetação. Na Figura 3a está o mapa de uso da terra gerado visualmente. A imagem mascarada a partir do mapeamento visual pode ser vista na figura 3b. Na Figura 3c está o mapa de uso classificado automaticamente pelo Texture, com as medidas *cluster shade* e a variância do vetor soma, quantização de 256 níveis de cinza e janela de 3x3 *pixels*.

A matriz de confusão (Tabela 5) demonstra os erros cometidos pela classificação automática. Nas linhas estão os dados obtidos pelo mapa classificado e, nas colunas, os dados do mapa de referência, mapeado visualmente e conferido em campo. A precisão geral do mapa ficou em 92%. Já o índice kappa, ficou em 86% que, segundo Galparsoro e Fernández (2001) é muito bom. A precisão geral é calculada pela razão entre os *pixels* corretamente classificados automaticamente e o total de *pixels* de referência. Uma vez que não considera os erros de omissão e comissão implícitos no restante da matriz, a precisão geral normalmente fornece valores mais altos, quando comparados a outros índices, como o kappa (Bernardes, Alves *et al.*, 2007).

Na Tabela 6, a matriz de confusão foi transformada em valores percentuais. Na diagonal dessa tabela vê-se a precisão de cada classe temática. A classe de maior precisão foi a de Outros Usos porque a mesma estava mascarada. Entre as classes de café e mata, a precisão fica em torno de 83%. Os valores da Tabela 6 que estão fora da diagonal referem-se aos erros de omissão e de inclusão de cada classe. O erro de omissão acontece quando determinada feição que deveria ser classificada em dada classe temática é classificada como pertencente à outra classe (Leão *et al.*, 2007). O erro de omissão da classe café foi de 18%, a da mata foi de 16%, e a de outros usos ficou em 1%.




Figura 3a. Mapa de uso da terra gerado visualmente no SPRING, utilizando as bandas 3, 4 e 5 do satélite Landsat 5, sensor TM.




Figura 3b. Imagem TM-Landsat 5, banda 4, mascarada.




Figura 3c. Mapa de uso da terra gerado automaticamente no Texture, utilizando a bandas 4 do satélite Landsat 5, sensor TM.

O erro de inclusão acontece quando uma feição é classificada como uma classe temática que não corresponde à realidade (Leão, Krug *et al.*, 2007). Os erros de inclusão ficaram em 15% para a classe café, 21% para a classe mata e de 0% para a classe Outros Usos.

Tabela 5. Matriz de confusão – em *pixels*.

Plano-1 (nas linhas): Classificado				
Plano-2 (nas colunas): Mapa de Referência				
	Café	Mata	Outros Usos	Total
Café	1031936	174791	8655	1215382
Mata	227680	929701	14403	1171784
Outros Usos	57	170	2810007	2810234
Total	1259673	1104662	2833065	5197400

Tabela 6. Parâmetros estatísticos derivados da matriz de confusão - porcentagem.

Plano-1 (nas linhas) :Classificado			
Plano-2 (nas colunas): Mapa de Referência			
	Café	Mata	Outros Usos
Café	81.92	15.82	0.31
Mata	18.07	84.16	0.51
Outros Usos	0.00	0.02	99.19

5. Considerações Finais

A precisão geral e o índice kappa demonstraram a eficácia dos atributos de textura na separabilidade entre as classes temáticas de café e mata.

A classe temática mata foi mais bem mapeada do que a classe café, isso porque áreas de café em formação não possuem um padrão de reflectância semelhante ao do café formado, sendo sua resposta espectral influenciada por outros alvos, como a cobertura do solo.

O classificador textural clatex do SPRING foi testado com os mesmos parâmetros do Texture, porém os resultados não foram satisfatórios. Numa comparação entre os dois classificadores, o clatex possui maior complexidade de utilização e menor controle sobre os dados de entrada. A grande vantagem do Texture é permitir escolher os polígonos a serem classificados.

Nos classificadores convencionais, quando não são dadas amostras de um determinado alvo, o classificador não o classifica. Os classificadores texturais Clatex e Textre não deixam áreas sem classificar, o que é ruim, pois acabam associando alvos com características totalmente diferentes.

Acredita-se que a classificação textural pode ser utilizada em conjunto com os classificadores convencionais. Os classificadores convencionais excluiriam a classe temática 'outros usos' da imagem a ser classificada, funcionando posteriormente como máscara. Os classificadores texturais agiriam na separabilidade entre áreas de mata e cafeicultura.

Agradecimentos

Este trabalho foi financiado pelo Consórcio Brasileiro de Pesquisa e Desenvolvimento do Café (CBP&D Café). Os autores agradecem também à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) por financiar bolsas de pesquisas.

Referências Bibliográficas

Batista, G. T., Tardin, A. T., Chen, S. C. e Dallemand, J. F. Avaliação de produtos HRV/SPOT e TM/LANDSAT na discriminação de culturas. *Pesquisa Agropecuária Brasileira*, v.25, n.3, p.379-386, 1990.

- Bernardes, T., Alves, H. M. R., Vieira, T. G. C. e Andrade, H. Avaliação da acurácia do mapeamento do uso da terra no complexo Serra Negra, Patrocínio, MG, por interpretação visual e classificação automática de imagens Landsat. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. **Anais**. São José dos Campos : INPE, 2007. Artigos, 21-26 abril, p. 5587-5594. Disponível em: < <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.14.10.39/doc/5587-5594.pdf> >. Acesso em: 20 out. 2008.
- Câmara, G., Souza, R. C. M., Freitas, U. M. e Garrido, J. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v.20, n.3, May/June 1996, p.395-403, 1996.
- Connors, R. W., Trivedi, M. M. e Harlow, C. A. Segmentation of a high-resolution urban scene using texture operators. **Computer vision, graphics and image processing**, v.25, p.273-310, 1984.
- Dallemand, J. F. **Identificação de culturas de inverno por interpretação visual de dados SPOT e Landsat/TM no Noroeste do Paraná**.1987. 131 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.1987.
- Fernandes, S. C. **Avaliação de imagens de satélite de alta e muito alta resolução espacial para a discriminação de classes de uso e ocupação do solo : aplicação ao caso da sub-bacia do córrego Capão Comprido no Distrito Federal**.2005. 106p p. (Mestrado em Engenharia Civil e Ambiental) - Universidade de Brasília, Brasília.2005.
- Galparsoro, L. U. e Fernández, S. P. Medidas de concordancia: el índice Kappa. **Cad Aten Primaria**, p. 169-171, 21 out. 2008 2001. Disponível em: < <http://www.fisterra.com/mbe/investiga/kappa/kappa.htm> >.
- Haralick, R. M., Shanmugam, K. e Dinstein, I. H. Textural Features for Image Classification. **Systems, Man and Cybernetics, IEEE Transactions on**, v.3, n.6, p.610-621, 1973.
- Leão, C., Krug, L. A., Kampel, M. e Fonseca, L. M. G. Avaliação de métodos de classificação em imagens TM/Landsat e CCD/CBERS para o mapeamento do uso e cobertura da terra na região costeira do extremo sul da Bahia. In: XIII Simpósio Brasileiro de Sensoriamento Remoto, 2007, Florianópolis. **Anais**. São José dos Campos: INPE, 2007. Artigos,, p. 939-946.
- Medeiros, A. M. P., Rudorff, B. F. T. e Shimabukuro, Y. E. Imagens Landsat na Estimativa de Áreas de Cana-de-Açúcar, Milho e Soja. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 8, 1996, Salvador/BA. **Anais**. São José dos Campos: INPE, 1996. Artigos, 14-19 abril, p. 33-37. Disponível em: < <http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.01.11.30/doc/T85.pdf> >. Acesso em: 01 out. 2008.
- Moreira, M. A. Uso da geotecnologia para avaliar e monitorar a cafeicultura brasileira : fase 1 - Estado de Minas Gerais. São José dos Campos/SP, 2007. Disponível em: < http://www.dsr.inpe.br/cafesat/data%5Cartigos%5CRelatorio_Cafe.pdf >. Acesso em: 3 nov. 2008.
- Moreira, M. A., Adami, M. e Rudorff, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat. **Pesquisa Agropecuária Brasileira**, v.39, n.3, p.223-231, 2004.
- Rennó, C. D., Freitas, C. D. C. e Sant'anna, S. J. S. A system for region image classification based on textural measures. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 9, 1998, Santos/SP. **Anais**. São José dos Campos: INPE, 1998. Artigos, 11-18 Set. , p. 1195-1202. Disponível em: < http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.11.14.26/doc/10_211o.pdf >. Acesso em: 20 out. 2008.
- Tardin, A. T., Assunção, G. V. e Soares, J. V. Análise preliminar de imagens TM visando a discriminação de café, citrus e cana-de-açúcar na região de Furnas-MG. . **Pesquisa Agropecuária Brasileira**, v.27, n.9, set. 1992, p.1355-1361, 1992.
- Vieira, T. G. C., Alves, H. M. R., Bertoldo, M. A. e Souza, V. C. O. Geotechnologies in the assessment of land use changes in coffee regions of the state of Minas Gerais in Brasil. **Coffee Science**, v.2, p.142-149, 2007a.
- Vieira, T. G. C., Alves, H. M. R., Lacerda, M. P. C., Veiga, R. D. e Epiphanyo, J. C. N. Crop parameters and spectral response of coffee (*Coffea arabica* L.) areas within the state of Minas Gerais, Brazil. **Coffee Science**, v.1, n.2, p.111-118, 2006.
- Vieira, T. G. C., Alves, H. M. R., Volpato, M. M. L., Souza, V. C. O. e Bernardes, T. Sistema de geoinformação para a cafeicultura do Sul de Minas. **Informe Agropecuário** v.28, n.241, nov./dez., p.16-26, 2007b.
- Welch, R. M., Kuo, K. e Sengupta, S. K. Cloud and surface textural features in polar regions. **IEEE transactions on Geoscience and Remote Sensing**, v.28, n.3, p.520-528, 1990.

Tabela 1. Valores médios de medidas texturais para banda 4, quantização 256, janela 3x3.

	Contraste	Entropia	Energia	Homog.	Chi-square	Cluster shade	Cluster prominence	Média do vetor soma	Variância do vetor soma	Entropia do vetor soma	Média do vetor diferença	Variância do vetor diferença	Entropia do vetor diferença	Contraste do vetor diferença
Café Produção	25335.00	2.49	0.01	0.21	4.62	-15402455.53	4065509574.47	320.00	1482.20	1.89	6.21	41.15	1.05	49140.06
Mata	26478.96	2.65	0.00	0.14	4.01	-10861200.20	2705963000.00	284.45	2157.21	1.96	10.03	98.03	1.24	43973.04

Tabela 2. Valores médios de medidas texturais para banda 3, quantização 256, janela 3x3.

	Contraste	Entropia	Energia	Homog.	Chi-square	Cluster shade	Cluster prominence	Média do vetor soma	Variância do vetor soma	Entropia do vetor soma	Média do vetor diferença	Variância do vetor diferença	Entropia do vetor diferença	Contraste do vetor diferença
Café Produção	24535.29	1.91	0.02	0.21	2.11	1242.48	1251052.83	123.38	442.85	1.44	7.33	53.04	0.96	13530.00
Mata	23970.09	1.78	0.03	0.23	1.72	3068.49	529200.00	113.38	293.39	1.34	7.24	51.93	0.94	9829.00

Tabela 3. Valores médios de medidas texturais para banda 5, quantização 256, janela 3x3.

	Contraste	Entropia	Energia	Homog.	Chi-square	Cluster shade	Cluster prominence	Média do vetor soma	Variância do vetor soma	Entropia do vetor soma	Média do vetor diferença	Variância do vetor diferença	Entropia do vetor diferença	Contraste do vetor diferença
Café Produção	28891.34	2.56	0.00	0.15	3.17	1975.65	260442.27	113.20	225.19	1.70	4.75	20.88	1.11	7553.11
Mata	28514.67	2.45	0.01	0.14	3.10	2149.98	338424.33	94.36	244.10	1.66	6.08	33.84	1.17	5878.86

Tabela 4. Valores médios de medidas texturais para banda 4, quantização 128, janela 3x3.

	Contraste	Entropia	Energia	Homog.	Chi-square	Cluster shade	Cluster prominence	Média do vetor soma	Variância do vetor soma	Entropia do vetor soma	Média do vetor diferença	Variância do vetor diferença	Entropia do vetor diferença	Contraste do vetor diferença
Café Produção	26478.38	2.49	0.01	0.25	4.57	-1596.22	603113.39	159.53	368.85	1.82	3.18	10.75	0.97	12339.15
Mata	27854.72	2.65	0.00	0.18	4.09	-2617.52	1276479.10	141.75	537.14	1.88	5.13	25.42	1.15	11033.82