
ACURÁCIA TEMÁTICA DO CLASSIFICADOR POR MÁXIMA VEROSSIMILHANÇA EM IMAGEM DE ALTA RESOLUÇÃO ESPACIAL DO SATÉLITE GEOEYE-1

MENDES, Danilo Ferreira¹
SILVA, Samuel Ferreira da²
FERRARI, Jéferson Luiz³
SANTOS, Alexandre Rosa dos⁴
GARCIA, Ricardo Ferreira⁵

Recebido em: 2013.11.19

Aprovado em: 2015.04.22

ISSUE DOI: 10.3738/1982.2278.1011

RESUMO: Este estudo avalia a acurácia temática do classificador máxima verossimilhança em uma imagem de alta resolução espacial do satélite Geoeye-1. A área em estudo refere-se à sub-bacia hidrográfica do córrego Horizonte, Alegre, ES e as classes analisadas foram área agricultada, área urbana, fragmento florestal, hidrografia, pastagem e solo exposto. A qualidade do mapa temático foi avaliada pela estatística kappa, exatidão global, acurácias do produtor e do usuário, tendo como referência o mapeamento das classes na escala cartográfica de 1:2.000. Os resultados mostram que a classificação automática conferida pelo classificador apresenta bons resultados de índice kappa (58,34%) e de exatidão global (71,41%). Dentre as classes avaliadas, as de fragmento florestal e de pastagem foram aquelas que apresentaram as melhores exatidões e precisões. O reconhecimento das demais classes como área agricultada, área urbana, hidrografia e solo exposto, em função da complexidade da paisagem e de suas pequenas dimensões na área de estudo, depende do uso de técnicas de fotointerpretação para maiores precisões.

Palavras-chave: Sensoriamento remoto. Classificação de imagens. Índice kappa.

THEMATIC ACCURACY OF THE MAXIMUM LIKELIHOOD CLASSIFIER IN HIGH SPATIAL RESOLUTION IMAGING SATELLITE GEOEYE-1

SUMMARY: This study evaluates the thematic accuracy of the maximum likelihood classifier in a high spatial resolution imaging satellite GeoEye-1. The study area refers to the sub-basin of the stream Horizonte, Alegre, ES and the classes were analyzed agriculture area, urban area, forest fragmentation, hydrography, pasture and bare soil. The quality of the thematic map was assessed using the kappa statistic, overall accuracy, producer's accuracies and user, with reference to the mapping of classes in the scale of 1:2,000 mapping. The results show that automatic classification given by the classifier gives good results for kappa (58.34%) and overall accuracy (71.41%). Among the classes evaluated, the fragment forest and pasture were those with the best accuracies and precisions. The recognition of other classes as agriculture area, urban area, hydrography and exposed soil, depending on the complexity of the landscape and its small dimensions in the study area, depends on the use of image interpretation techniques for further details.

Keywords: Remote sensing. Image classification. Kappa index.

¹Graduado em Tecnologia em Cafeicultura, Pós Graduando em Agroecologia pelo Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo - IFES - campus de Alegre. daniolfmendes@gmail.com (autor para correspondência)

²Doutorando em Produção Vegetal pela Universidade Federal do Espírito Santo – UFES. Centro de Ciências Agrárias - Departamento de Engenharia Rural.

³Professor do Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo - IFES - campus de Alegre. Departamento de Desenvolvimento Educacional.

⁴Professor Associado da Universidade Federal do Espírito Santo – UFES. Centro de Ciências Agrárias - Departamento de Engenharia Rural.

⁵Professor Associado da Universidade Estadual Norte Fluminense - UENF/LEAG. Centro de Ciências e Tecnologias Agropecuárias

INTRODUÇÃO

O sensoriamento remoto desempenha um papel fundamental no mapeamento, cadastramento e monitoramento de recursos naturais, onde a classificação digital de imagens é, entre as técnicas de processamento, a mais importante na obtenção de informações específicas dos ambientes de interesse (SOUZA *et al.*, 2007; LIU, 2007; JENSEN, 2009).

Segundo Moreira (2007), a classificação é um processo que consiste em categorizar automaticamente todos os pixels de uma determinada imagem, atribuindo a cada pixel um rótulo que contenha as informações de um objeto do mundo real. Em alguns casos, afirma o autor, a classificação pode ser o próprio objeto final de análise.

Diversos métodos estatísticos de reconhecimento de padrões têm sido explorados para classificação de imagens de sensoriamento remoto (PEDRINI; SCHWARTZ, 2008). No entanto, observa-se que o algoritmo de classificação por máxima verossimilhança é o classificador mais largamente empregado no processo da identificação e delineamento das classes (LIU, 2007; JENSEN, 2009).

Poucos são os estudos que têm avaliado o desempenho de algoritmos de classificação digital em imagens de satélite de alta resolução espacial. Tais produtos orbitais representam, atualmente, uma das maiores evoluções da ciência e tecnologia espacial, permitindo um detalhamento de objetos sem precedente na história. Em setembro de 2008, a Empresa Norte Americana Geoeye, lançou o Satélite Geoeye-1 com a capacidade de recolher imagens com uma resolução no solo de 41 cm no módulo pancromático - PAN e 1,6 m no multiespectral - MS (EMBRAPA, 2012).

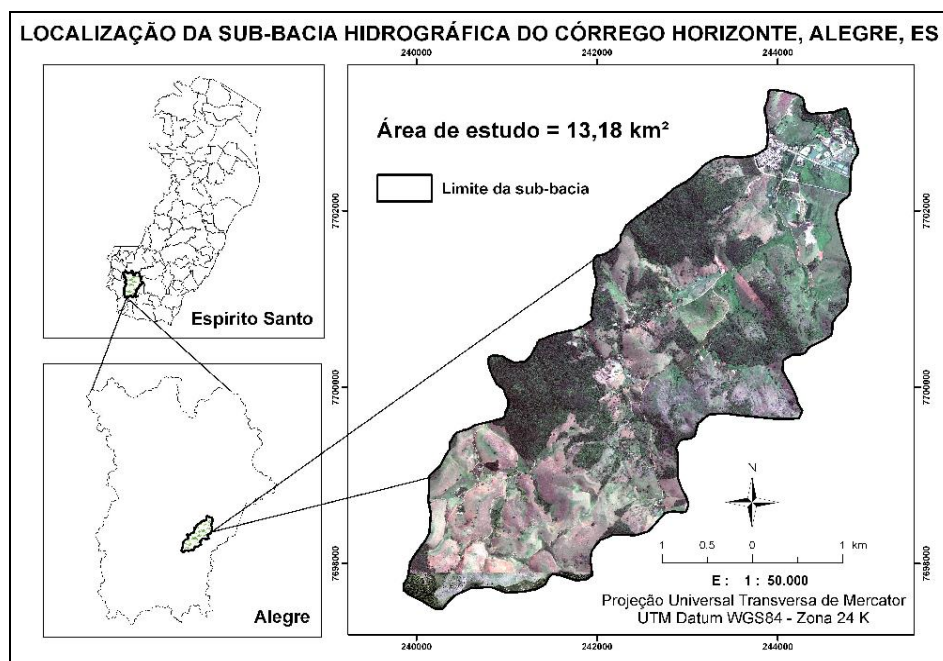
A resolução espacial ou geométrica, segundo Moreira (2007), refere-se ao campo de visada instantânea - IFOV (do inglês, *Instantaneous Field of View*), ou seja, a área detectada por determinado sensor sobre a superfície da Terra dentro de um ângulo sólido. Na prática, para o usuário de dados de sensoriamento remoto, o IFOV está intimamente relacionado com o tamanho do *pixel*. Em geral, apenas objetos maiores do que a área do *pixel* pode ser identificada, embora isso também dependa da reflectância e contraste entre objetos próximos.

O interesse pelas imagens de alta resolução espacial para aumentar a confiabilidade dos mapeamentos temáticos, tem aumentado, fazendo-se necessárias as realizações de pesquisas com os mais variados tipos de classificadores. Com este viés científico, objetivou-se com este trabalho avaliar a acurácia temática do classificador de máxima verossimilhança no processo de identificação e delineamento de classes representativas de uso e cobertura da terra a partir de uma imagem de alta resolução espacial do satélite Geoeye-1.

MATERIAL E MÉTODO

O estudo foi conduzido na sub-bacia hidrográfica do córrego do Horizonte, situada a 10 km do município de Alegre - ES, nas coordenadas geográficas de 20°45'51" latitude Sul e 41°27'24" longitude Oeste (Figura 1).

Figura1. Localização da área de estudo.



O clima da região é do tipo “Cwa”, ou seja, quente úmido no verão, com inverno frio e seco. A temperatura média anual é de 23,1° C e a precipitação média anual é de 1.341 mm (LIMA *et al.*, 2008).

Os solos da região são representados por: Latossolo Vermelho Amarelo Álico A moderado, Latossolo Una Álico A moderado, Cambissolo Álico Tb A moderado, com texturas de média a argilosa, e relevo variando de fortemente ondulado a montanhoso (IBGE, 1994).

O uso e cobertura da terra na região são constituídos principalmente por pastagens, culturas anuais, culturas perenes e remanescentes florestais em estágio sucessional da tipologia da floresta subperinifólia, sob o domínio da Floresta Atlântica (AEEE, 2008). Destaca-se que nesta sub-bacia há também um considerável desenvolvimento urbano motivado pela localidade de Rive – distrito de Alegre e pela sede do Instituto Federal do Espírito Santo – Campus de Alegre.

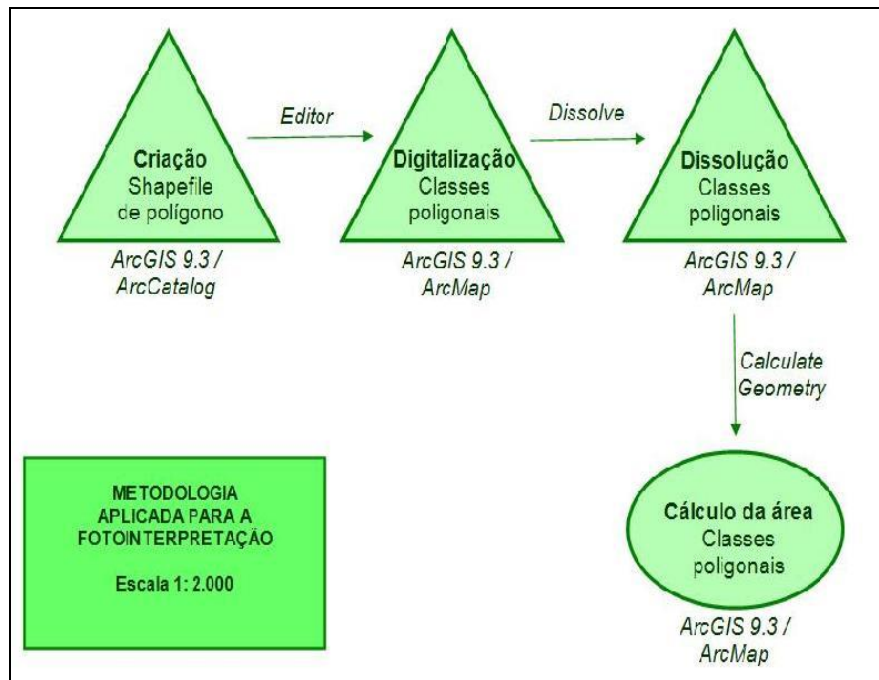
Para a realização deste trabalho foi utilizada imagem ortoretificada do sensor do satélite Geoeye – 1, georreferenciada no Datum WGS 84, com data de aquisição de 29 de outubro de 2009, compreendida na Zona 24 K pelas coordenadas UTM: canto inferior esquerdo N1 = 7.695.490,436 e E1 = 237.886,814; e de canto superior direito N2 = 7.705.1379,460 e E2 = 246.820,254.

De acordo com Geoeye (2012), a imagem contém as bandas pancromática (0,45 a 0,80 μm), azul (0,45 a 0,51 μm), verde (0,51 a 0,58 μm), vermelho (0,65 a 0,69 μm) e infravermelho próximo (0,78 a 0,92 μm), com resolução espacial de 0,41 m na PAN e 1,65 m na MS.

Os processamentos e a análise da acurácia foram feitos empregando, respectivamente, os sistemas de informações geográficas ArcGIS 9.3® (ESRI, 2006) e Idrisi Andes® (CLARKS LABS, 2006). A metodologia empregada foi subdividida nas seguintes etapas: a) fotointerpretação das classes de uso e cobertura da terra na sub-bacia hidrográfica; b) classificação temática; c) aferição da acurácia temática.

Os procedimentos envolvidos na fotointerpretação das classes são mostrados na Figura 2. Destaca-se que os resultados dos cálculos das áreas de cada classe, compatíveis com a escala cartográfica de 1:2.000 foram considerados neste trabalho, como a verdade de campo.

Figura 2. Fluxograma dos procedimentos realizados para a obtenção dos dados de referência.




A classificação temática foi realizada por meio do classificador máxima verossimilhança, desenvolvida em função da seleção de áreas de treinamento confiáveis. Foram selecionadas as seguintes classes temáticas: área agricultada, área urbana, fragmento florestal, hidrografia, pastagem e solo exposto. A Tabela 1 sintetiza as principais características das classes amostradas, mostrando como foi organizado o reconhecimento das assinaturas espectrais.

Tabela 1. Características das classes amostrais de treinamento

| Classes | Descrição | Amostra/ Classe | Cor/ Legenda |
|---------------------|--|--------------------|-----------------|
| Área agricultada | Cultivo de café, citros manga, goiaba etc. | | |
| Área urbana | Edificações, estradas pavimentadas e não pavimentadas. | | |
| Fragmento florestal | Vestígios de vegetação da mata atlântica e áreas reflorestadas. | | |
| Hidrografia | Espelho d'água de rios, tanques de piscicultura, lagos e lagoas. | | |
| Pastagem | Pastos naturais e melhorados. | | |
| Solo Exposto | Solos erodidos e recém-arados. | | |

Na Figura 3 é mostrado os procedimentos em cada um dos dois sistemas de informações geográficas utilizados. O sistema aplicativo computacional Idrisi Andes® foi empregado apenas para a geração da matriz de erro.

Figura 3. Fluxograma dos procedimentos realizados para a classificação supervisionada e análise da acurácia temática.



A matriz de erro utilizada para a aferição da acurácia temática foi construída segundo o modelo apresentado na Tabela 2, pela qual foram obtidas as seguintes estatísticas: índice kappa (Equação 1), exatidão global (Equação 2), as acurácias do produtor (Equação 3) e do usuário (Equação 4).

Tabela 2. Modelo da matriz de erro utilizada para a aferição da acurácia temática

| Matriz 4 x 4 | | | | | | |
|---------------------|----|----------|----------|----------|----------|-----------------|
| Classes | | A. | B | C | D | Soma das linhas |
| Dados classificados | A. | n_{11} | n_{12} | n_{13} | n_{1k} | n_{1+} |
| | B | n_{21} | n_{22} | n_{23} | n_{2k} | n_{2+} |
| | C | n_{31} | n_{32} | n_{33} | n_{3k} | n_{3+} |
| | D | n_{41} | n_{42} | n_{43} | n_{4k} | n_{k+} |
| Soma de colunas | | n_{+1} | n_{+2} | n_{+3} | n_{+k} | n |

Fonte: Adaptado de Congalton e Green (2009) e Santos (2010).

$$\text{Índice kappa} = \frac{\sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} + n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} + n_{+i}} \quad (1)$$

$$\text{Exatidão global} = \frac{\sum_{i=1}^k n_{ij}}{n} \quad (2)$$

$$\text{Acurácia do produtor } j = \frac{n_{ij}}{n_{+j}} \quad (3)$$

$$\text{Acurácia do usuário} = \frac{n_{ii}}{n_{i+}} \quad (4)$$

A qualidade da classificação, associada aos valores da estatística kappa, foi avaliada conforme Landis e Kock (1977) (Tabela 3).

Tabela 3. Níveis de exatidão de uma classificação, conforme o valor de índice kappa

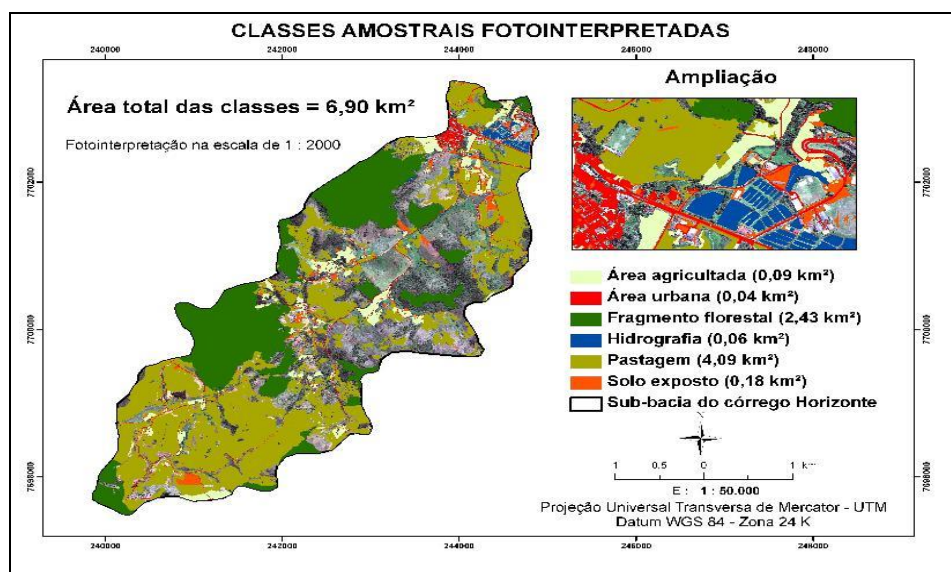
| Índice kappa (K) | Qualidade |
|------------------|-----------|
| K = 0,2 | Ruim |
| 0,2 < K = 0,4 | Razoável |
| 0,4 < K = 0,6 | Bom |
| 0,6 < K = 0,8 | Muito Bom |
| K = 0,8 | Excelente |

Fonte: Adaptado de Landis e Kock (1977)

RESULTADO E DISCUSSÃO

O resultado do mapeamento das classes amostrais pela técnica de fotointerpretação é apresentado na Figura 4. Nota-se que a área total das classes selecionadas soma 6,90 km², o que representa 52,35% da área total da sub-bacia hidrográfica do córrego Horizonte (13,18 km²).

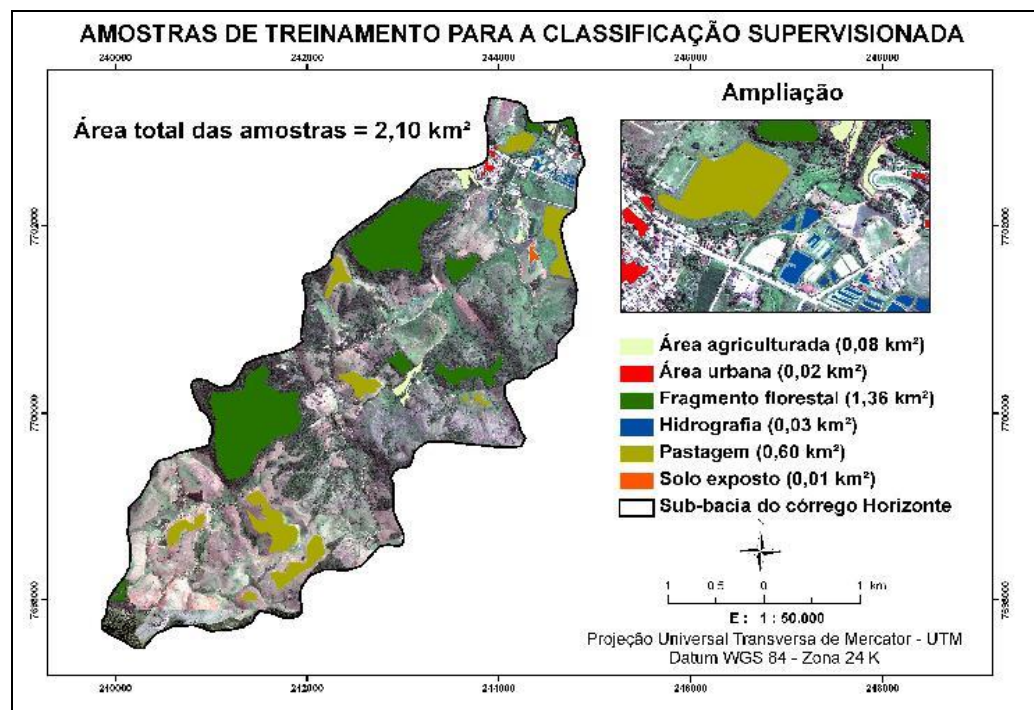
Figura 4. Mapeamento das classes amostrais com base na fotointerpretação.



A quantificação das classes amostrais em relação à área de estudo (13,18 km²), denota que os maiores percentuais encontrados de uso e cobertura da terra na sub-bacia hidrográfica do córrego Horizonte foram de pastagem (4,09 km²) e fragmento florestal (2,43 km²), perfazendo 31,01% e 18,43%, respectivamente. As demais classes são representadas na sub-bacia hidrográfica com os seguintes percentuais, numa ordem decrescente: solo exposto (0,18 km² ou 1,36%), área agricultada (0,09 km² ou 0,68%), hidrografia (0,06 km² ou 0,45%) e área urbana (0,04 km² ou 0,30%).

A Figura 5 exhibe as amostras de treinamento que guiaram a classificação por máxima verossimilhança. A área total amostrada tem aproximadamente 210 hectares (2,10 km²). Destaca-se o cuidado neste trabalho de fornecer ao processo de classificação supervisionada, amostras de treinamento representativas no que se referem ao tamanho, homogeneidade e distribuição espacial das classes amostrais fotointerpretadas.

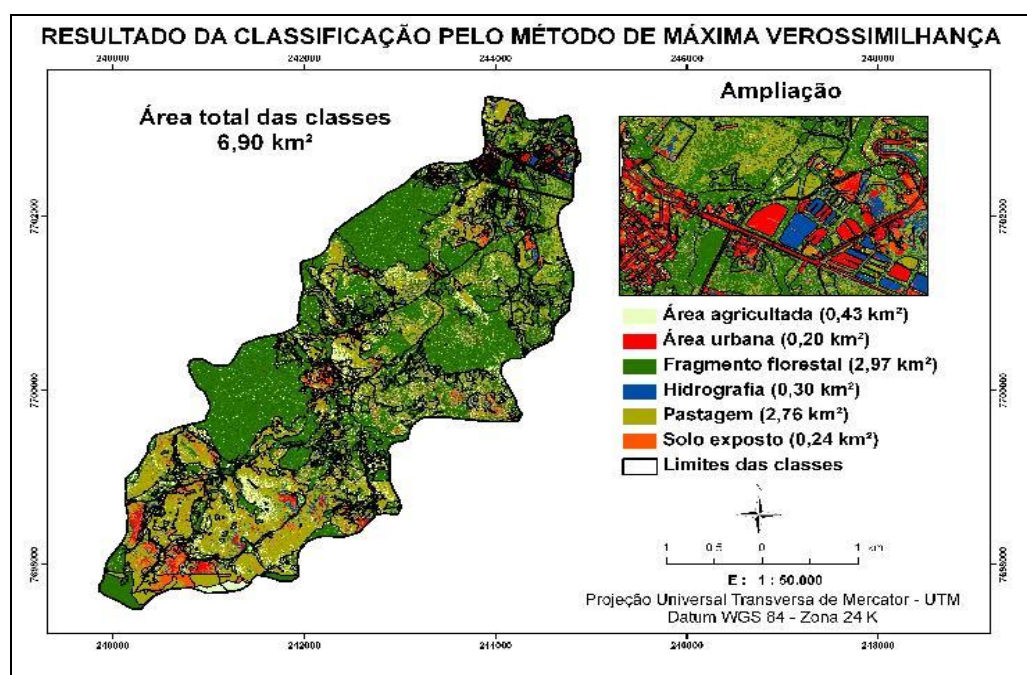
Figura 5. Áreas de treinamento digitalizadas para a classificação supervisionada.



O mapeamento resultante da classificação supervisionada e os erros relativos às diferenças de áreas de cada classe são apresentados na Figura 6 e Tabela 4, respectivamente.

Segundo Moreira (2007), a qualidade de um mapa temático é avaliada com base em dois quesitos: a precisão e exatidão ou acurácia de mapeamento. Enquanto que a precisão do mapeamento significa quanto à área de cada classe reflete a verdade no campo, a exatidão é um número (índice) que avalia o posicionamento da distribuição espacial de cada uma das classes que foram mapeadas.

De modo geral, ao se comparar as precisões dos mapeamentos obtidos constatam-se grandes diferenças entre áreas fotointerpretadas e classificadas.

Figura 6. Mapeamento da classificação por Máxima Verossimilhança.

Salienta-se que essas diferenças retratam a precisão do mapeamento, mostrando quanto à área de cada classe reflete a verdade no campo. Os resultados mostram que as piores precisões ocorreram nas classes de área agricultada (0,34 km² ou 377,77%), área urbana (0,16 km² ou 400,00%) e hidrografia (0,24 km² ou 400,00%). E, as melhores precisões foram alcançadas nas classes de fragmento florestal (0,54 km² ou 22,22%), pastagem (-1,33 km² ou -32,52%) e solo exposto (0,06 km² ou 33,33%).

Tabela 4. Comparação das áreas das classes amostrais obtidas pelos métodos da fotointerpretação e da classificação por Máxima Verossimilhança para a sub-bacia hidrográfica do córrego Horizonte, Alegre – ES

| CLASSES | Fotointerpretação (km ²) | Maxver (km ²) | Diferença (km ²) | Diferença (%) |
|---------------------|---|------------------------------|---------------------------------|------------------|
| Área agricultada | 0,09 | 0,43 | 0,34 | 377,77 |
| Área urbana | 0,04 | 0,20 | 0,16 | 400,00 |
| Fragmento florestal | 2,43 | 2,97 | 0,54 | 22,22 |
| Hidrografia | 0,06 | 0,30 | 0,24 | 400,00 |
| Pastagem | 4,09 | 2,76 | -1,33 | -32,52 |
| Solo exposto | 0,18 | 0,24 | 0,06 | 33,33 |
| Total | 6,90 | 6,90 | | |

Pela análise visual da imagem de referência, observa-se que a causa principal das áreas superestimadas se deve a complexidade da paisagem local, devido, particularmente, às semelhanças

espectrais entre as áreas das classes área agricultada, área urbana, hidrografia e solo exposto. Esses resultados estão de acordo com o trabalho desenvolvido por Raptis *et al.*, (2003).

É válido comentar também que, quanto melhor a resolução espacial do sistema sensor, dada a alta quantidade de pixels, maior a discriminação de outros objetos intrínsecos na amostra, o que provoca maior variabilidade espectral em uma mesma classe.

Por meio da matriz de erro apresentada na Tabela 5, pode-se observar a exatidão do mapeamento através dos dados de validação cruzada entre o mapa fotointerpretado e o mapa resultante da classificação. Os valores da diagonal principal (em negrito) referem-se à porcentagem das amostras de cada classe corretamente classificadas.

Tabela 5. Matriz de erro para a análise da acurácia obtida na classificação digital

| Matriz 6 X 6 | | Classes fotointerpretadas (Verdade de campo) | | | | | | | |
|--------------------------------------|----------------|--|----------------|-----------------|-----------------|---------------|--------------|---------------|---------------|
| Classes resultantes da classificação | Classes | Área agricult. | Área urbana | Frag. florestal | Hidrografia | Pastagem | Solo exposto | Soma linhas | Erro comissão |
| | Área agricult. | 15020 | 8332 | 184177 | 4695 | 1484986 | 30008 | 1727218 | 0,9913 |
| Área urbana | 4116 | 72024 | 1104 | 68763 | 515285 | 144745 | 806037 | 0,9106 | |
| Frag. florestal | 232981 | 11151 | 9016409 | 23790 | 2572160 | 40757 | 2533255 | 0,2421 | |
| Hidrografia | 19664 | 7803 | 35731 | 84445 | 1020937 | 22689 | 1191269 | 0,9291 | |
| Pastagem | 86273 | 18712 | 463987 | 49249 | 10188793 | 174257 | 10981271 | 0,0722 | |
| Solo exposto | 5394 | 50389 | 2739 | 14118 | 580683 | 319331 | 12172540 | 0,6717 | |
| Soma colunas | 363448 | 168411 | 9704147 | 245060 | 16362844 | 731787 | 27575697 | | |
| Erro omissão | 0,9587 | 0,5726 | 0,0714 | 0,6554 | 0,3778 | 0,5639 | | 0,2863 | |

De acordo com Hay (1988), o uso da matriz de erro permite, entre outros, alcançar os objetivos como o ajuste das áreas das classes obtidas por algum tipo de classificação, o cálculo de parâmetros de exatidão geral da classificação, e a identificação de erros específicos que afetam cada uma das categorias.

Utilizando os dados de validação cruzada, obtiveram-se os seguintes índices para a aferição da acurácia temática. De acordo com Landis e Kock (1977) e Congalton e Green (2009) os valores de índice kappa (58,34%) e exatidão global (71,41%) encontrados são considerados de boa aceitação. O valor do índice kappa ser menor que a exatidão global justifica-se pelo fato de o índice kappa considera todas as células da matriz de erro.

Abaixo é mostrada a memória de cálculo para a determinação de tais índices.

$$\text{Índice kappa} = \frac{\sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} + n_{+i}}{n^2 - \sum_{i=1}^k n_i + n_{+1}} = \frac{19696022 - 8660311}{27575697 - 8660311} = \frac{11035711}{18915386} = 0,5834 = 58,34\%$$

$$\text{Exatidão global} = \frac{\sum_{i=1}^k n_{ij}}{n}$$

$$= \frac{15020 + 72024 + 9016409 + 84445 + 10188793 + 319331}{27575697} = \frac{19696022}{27575697} = 0,7143 = 71,41\%$$

$$\text{Acurácia do produtor } j = \frac{n_{ij}}{n_{+j}}$$

$$\text{Área agricultada} = \frac{15020}{363448} = 0,0413$$

$$\text{Área urbana} = \frac{72024}{168411} = 0,4274$$

$$\text{Fragmento florestal} = \frac{9016409}{9704147} = 0,9286$$

$$\text{Hidrografia} = \frac{84445}{245060} = 0,3446$$

$$\text{Pastagem} = \frac{10188793}{16362844} = 0,6222$$

$$\text{Solo exposto} = \frac{319331}{731787} = 0,4361$$

$$\text{Acurácia do usuário} = \frac{n_{ii}}{n_{i+}}$$

$$\text{Área agricultada} = \frac{15020}{1727218} = 0,0087$$

$$\text{Área urbana} = \frac{72024}{806037} = 0,0894$$

$$\text{Fragmento florestal} = \frac{9016409}{2533255} = 0,7579$$

$$\text{Hidrografia} = \frac{84445}{1191269} = 0,0709$$

$$\text{Pastagem} = \frac{10188793}{10981271} = 0,9278$$

$$\text{Solo exposto} = \frac{319331}{12172540} = 0,3283$$

Observando esses resultados, percebe-se que a classe que apresentou os maiores erros de omissão e comissão foi a área agricultada, com cerca de 97% dos pixels que deveriam ser assinalados à esta classe, sendo assinaladas a outras. Situação semelhante foi notada para as classes área urbana e hidrografia que tiveram seus pixels assinalados erroneamente.

Por outro lado, as classes fragmento florestal e pastagem foram as que apresentaram os melhores resultados com acurácias do produtor (menores erros de omissão) e do usuário (menores erros de comissão) de 92,86% e 75,79% e 62,22% e 92,78%, respectivamente.

CONCLUSÃO

Os resultados mostram que a classificação automática conferida pelo classificador apresenta bons resultados de índice kappa (58,34%) e de exatidão global (71,41%). Dentre as classes avaliadas, as de fragmento florestal e de pastagem foram aquelas que apresentaram as melhores exatidões e precisões. O reconhecimento das demais classes como área agricultada, área urbana, hidrografia e solo exposto, em função da complexidade da paisagem e de suas pequenas dimensões na área de estudo, depende do uso de técnicas de fotointerpretação para maiores precisões.

AGRADECIMENTOS

Os autores agradecem à Prefeitura municipal de Alegre, ES pelas imagens orbitais de alta resolução espacial do satélite Geoeye-1 sem a qual não seria possível a realização deste estudo.

REFERÊNCIAS

- AEEE. **Atlas dos ecossistemas do Espírito Santo**. Viçosa: UFV, 2008. 504p.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2. ed. Taylor & Francis Group, 2009, 183p.
- CLARK LABS. **Idrisi andes for the desktop**. 15. ed., 2006.
- EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA EM AGROPECUÁRIA. **Sistemas Orbitais de Monitoramento e Gestão Territorial**. Campinas: Embrapa Monitoramento por Satélite, Disponível em: <<http://www.sat.cnpm.embrapa.br/>>. Acesso em: 10 jul. 2012.
- ESRI. **Environmental Systems Research Institute**. ArcGIS Professional GIS for the desktop, versão 9.2, 2006.
- GEOEYE. **Inovative geospatial products & solutions provider**. Disponível em: <<http://www.geoeye.com/>>. Acesso em: 10 jul. 2012.
- HAY, A. M. The derivation of global estimates from a confusion matrix. **International Journal of Remote Sensing**, v.9, n.8, p.1395-1398, 1988.
- IBGE. Instituto Brasileiro de Geografia e Estatística. **Mapa exploratório de solos do Projeto RADAM BRASIL**. IBGE, Rio de Janeiro. Escala 1:250000, Folha Cachoeiro, SF 24-V-A, 1994.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de EPIPHANIO, J. C. N. (Coordenador)...[*et al.*]. São José dos Campos: Parênteses, 2009. 598p.
- LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data **Biometrics**. **Washington**, v.33, n.3, p.159-179, 1977.
- LIMA, J. S. S. et al. Variabilidade temporal da precipitação mensal em Alegre – ES. **Revista Ciência Agrônômica**, Fortaleza, v.39, n.2, p.327- 332, 2008.
- LIU, W. T. **Aplicações de sensoriamento remoto**. Campo Grande- RJ: Ed UNIDERP, 2007. 865p.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3.ed. Viçosa, MG: UFV, 2007. 320p.
- PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008. 508p.
- RAPTIS, V. S.; VAUGHAN, R. A; WRIGHT, G. G. The effect of scaling on landcover classification from satellite data. **Computers & Geosciences**, v.29, n.6, p.705-714, 2003.
- SANTOS, A. R. S.; PELUZIO, T. M. O.; SAITO, N. S. **Spring 5.1.2 Passo a passo: Aplicações práticas**. Alegre, ES: CAUFES, 2010. 153p.

SOUZA, C. C.et al. Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil: uma revisão bibliográfica. **Ciência Florestal**, Santa Maria, v.17, n.4, p.409-417, 2007.