

Comparação entre as Classificações Híbrida e Supervisionada no Mapeamento do Uso do Solo Usando Imagens de Alta Resolução

Alessandra Lopes Braga ¹
Geíza Coutinho Figueiredo ²
Fabiana Gomes da Silva ³
Prof. PhD Vicente Paulo Soares ⁴

UFV – Depto. de Engenharia Civil
Informações Espaciais
36570-000 Viçosa-MG
¹alessandralb@hotmail.com
²geizacf@hotmail.com

UFV – Depto. de Engenharia Agrícola
36570-000 Viçosa-MG
³fabianagomessilva@hotmail.com

UFV – Depto. de Engenharia Florestal
36570-000 Viçosa-MG
⁴vicente@ufv.br

Resumo: As imagens obtidas por sensores de alta resolução espacial apresentam-se como uma alternativa para construção e atualização de bases cartográficas. O processo de classificação automática de imagens multiespectrais consiste em associar cada *pixel* da imagem a um rótulo ou classe descrevendo um objeto real, onde o classificador supervisionado da Máxima Verossimilhança (MaxVer) é o mais aplicado para dados de satélite. Neste contexto, desenvolveu-se este trabalho com o objetivo de comparar dois métodos de classificação em imagens digitais multiespectrais de alta resolução do sensor Ikonos II, para o mapeamento da cobertura terrestre. Os resultados mostraram valores de índices kappa muito próximos para os dois processos de classificação

Palavras chaves: Sensoriamento Remoto, Classificação de Imagens.

Abstract: Images obtained from high spatial resolution sensors present as an alternative for construction and updating of cartographic bases. The process of multiespectral image classification consists of associating each pixel of the image to a label or class describing a real object, where Maximum Likelihood's supervised classifier (MaxVer) is the most applied for satellite data. Thus, this work was conducted with the objective of comparing two classification methods using high resolution multiespectral data obtained from Ikonos II, for Land Cover Mapping. Results showed Kappa index very similar for both classification algorithms.

Keywords: Remote Sensing, Image Classification.

1 Introdução

Nas últimas décadas assistiu-se uma notável evolução das tecnologias destinadas a observação e medição da Terra. O sensoriamento remoto é uma das tecnologias que apresentam um alto nível de desenvolvimento, por receberem grandes investimentos. Hoje em dia, encontram-se disponíveis imagens oriundas dos mais diversos tipos de sensores, com diferentes resoluções espaciais, espectrais, radiométricas e temporais; abrindo-se um enorme leque de opções para profissionais que trabalham com imageamento (Alves e Vergara, 2005).

Imagens obtidas por sensores de alta resolução espacial, como os transportados pelos satélites Ikonos II e QuickBird, apresentaram-se como uma suposta alternativa para construção e atualização de bases cartográficas, Nishida (1998). Com o lançamento do satélite Ikonos II, em 24 de setembro de 1999, foi dado início à produção de imagens de alta resolução espacial para fins comerciais.

O satélite Ikonos possui sensores capazes de gerar imagens com 1m de resolução espacial no modo pancromático e 4 m no modo multiespectral. O satélite está colocado em órbita de aproximação polar síncrono-solar a 680 km de altitude, permitindo passagens na mesma região a cada três dias. Também permite ser programado para fazer cobertura mono ou estereoscópica de áreas de interesse, com até 11 km x 11 km (Ishikawa, 2001).

Segundo Tisot *et. al.* (2005), a produção de mapas temáticos, como os de uso e cobertura do solo, através da classificação de imagens é uma das aplicações mais utilizadas do sensoriamento remoto. O aumento da acurácia de classificação é um dos principais enfoques de estudo.

O processo de classificação automática de imagens multiespectrais de sensoriamento remoto consiste em associar cada *pixel* da imagem a um rótulo ou classe descrevendo um objeto real. Existem duas abordagens neste processo, a primeira denomina-se classificação supervisionada, onde o usuário identifica alguns dos *pixels* pertencentes às classes desejadas (formando a área de treinamento) e o software localiza todos os demais *pixels* pertencentes àquelas classes, baseado em alguma regra estatística pré-estabelecida. A segunda chama-se classificação não-supervisionada, nesta o próprio software decide, por análise de agrupamento, quais as classes a serem separadas e quais os *pixels* pertencentes a cada uma dessas classes (Crósta, 1993). A classificação não-supervisionada é também conhecida como classificação híbrida.

Dentre os algoritmos classificadores existentes, o de Máxima Verossimilhança (MaxVer) é o classificador supervisionado mais aplicado para dados de satélite. É um método paramétrico, o qual supõe que cada classe é determinada por um modelo gaussiano multivariado e determina, a partir de dados de treinamento, o vetor médio (m) e a matriz de covariância (S). A eficácia do MaxVer depende principalmente de uma precisão razoável da estimativa de m e de S , o que depende da quantidade de *pixels* incluídos nas amostras de treinamento (Tisot *et. al.*, 2005). Crósta (1993) considera que o método MaxVer deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que sejam representativas.

Neste contexto, desenvolveu-se este trabalho com o objetivo de comparar dois métodos de classificação em imagens digitais multiespectrais de alta resolução do sensor Ikonos II, para o mapeamento da cobertura terrestre.

2 Metodologia

A área de estudo está localizada no município de Serra do Salitre, Estado de Minas Gerais, compreendida entre as coordenadas UTM (Mercator Universal Transversal) 321.485,00 E e 7.869.137,00 N e 323.709,00 E e 7.867.049,00 N no fuso 23, no ponto de referência WGS84.

Os dados utilizados no estudo foram derivados de uma imagem obtida pelo satélite Ikonos II (Figura 1): bandas azul, verde, vermelho e infravermelho próximo, com resolução espacial de 4 metros, obtida em 2 de março de 2002.




Figura 1 : Composição 1, 2, 3 da imagem IKONOS

2.1 Classificação da imagem

Para a execução da classificação da imagem foi utilizado software *ERDAS/IMAGINE 8.5* conjuntamente com a imagem *subikonos.img*.

A partir de uma imagem referência de campo, foram coletadas amostras na imagem *subikonos.img* utilizadas no treinamento dos classificadores, as quais foram coletadas de duas maneiras: por *pixels* e por regiões. As amostras por regiões foram coletadas digitalizando-se polígonos sobre as classes de interesse na imagem.

Foram definidas as seguintes classes informacionais presentes na área (Tabela 1):

Tabela 1 – Classes informacionais.

1	Café
2	Mata Ciliar
3	Solo
4	Campo Limpo
5	Campo Sujo
6	Braquiária
7	Pasto

2.1.1 CLASSIFICAÇÃO SUPERVISIONADA

A classificação supervisionada pode ser definida como o processo de usar amostras de identidade conhecida para classificar *pixels* de identidade desconhecida. Neste tipo de classificação o analista conhece, a priori, a identidade e a localização de algumas feições, como corpos d'água, floresta, agricultura, solo, etc., a partir da análise de campo, fotografias aéreas, mapas e experiência pessoal. O analista procura localizar essas feições conhecidas em áreas específicas que representem exemplos homogêneos, o que se denominam amostras de treinamento.

Para proceder à classificação supervisionada três etapas são envolvidas:

- Seleção e coleta das amostras de treinamento

Nesta etapa do processo, foram feitas a digitalização dos polígonos para coletar as amostras de treinamento, de acordo com as classes definidas.

Evita-se coletar amostras próximas aos limites de outras classes para evitar impurezas nas amostras. Preferencialmente, as amostras deverão apresentar uma distribuição unimodal para cada banda para facilitar os procedimentos estatísticos posteriores.

- Avaliação e manipulação das amostras de treinamento

Esta etapa consiste na purificação das estatísticas das amostras de treinamento mediante fusão, eliminação, etc., tornando-as mais homogêneas possíveis de forma a propiciar uma classificação mais precisa.

Nesta fase pode-se verificar se as classes condiziam com a imagem de referência sendo estas mantidas, enquanto as classes que não apresentaram uma boa distinção podem ser eliminadas e algumas digitalizadas novamente, até obter um resultado satisfatório.

- Classificador

Nesta etapa efetuou-se a classificação propriamente dita, através do classificador da Máxima Verossimilhança.

Este algoritmo utiliza a média e a matriz de covariância das amostras de treinamento. Funções de densidade de probabilidade são utilizadas para classificar um *pixel* desconhecido computando a probabilidade de que aquele *pixel* venha a pertencer a uma dada categoria. Depois de avaliar a probabilidade para cada categoria, o *pixel* é assinalado à classe cuja probabilidade tenha sido a mais alta, ou a nenhuma delas no caso dos valores de probabilidade estar abaixo de um determinado limite estipulado pelo analista.

Utilizou-se um total de 30 interações a fim de evitar que o algoritmo rodasse por muito tempo sem alcançar um limiar de convergência.

2.1.2 Classificação Híbrida

Neste caso o classificador utiliza algoritmo para reconhecer as classes presentes na imagem no qual o treinamento é dito não supervisionado e a classificação não supervisionada. Esta classificação exige o mínimo de interferência do usuário.

No processo de classificação o algoritmo agrupa os *pixels* em diferentes classes espectrais de acordo com alguns critérios estatísticos pré-determinados. Uma primeira suposição é assumida para o centro de cada agrupamento. A distância Euclidiana entre cada *pixel* e o centro dos agrupamentos é calculada. Através de um processo iterativo o algoritmo vai mudando o centro dos agrupamentos até que as distâncias mínimas até o centro do agrupamento formam uma classe.

A classificação híbrida consiste em utilizar inicialmente um método de classificação não supervisionado e depois outro método de classificação supervisionado. É recomendada principalmente nas classificações que envolvem uma estratificação temática mais detalhada, ou seja, um grande número de temas a serem classificados (Venturieri e Santos, 1998). A classificação não supervisionada aplicada inicialmente permite a seleção de amostras mais homogêneas para o treinamento da fase supervisionada da classificação (Schowengerdt, 1997).

Para realizar a classificação não supervisionada procedeu-se da seguinte forma:

- Geração Classes Espectrais (*clusters*)

Para prevenir que o algoritmo rodasse por muito tempo em um ciclo sem atingir um limiar de convergência utilizou-se 30 iterações. Estipulou-se, a priori, 50 classes espectrais.

Para conversão das classes espectrais em classes informacionais, procedeu-se a identificação de qual feição que a classe espectral pertencia. Após esta identificação editaram-se as assinaturas (fusão, eliminação, etc.).

- Classificador

Utilizou-se o classificador da Máxima Verossimilhança para realizar uma classificação híbrida da imagem.

2.2 Avaliação da Exatidão das Imagens Classificadas

Os resultados da classificação digital de imagens só podem ser verificados se existirem dados confiáveis sobre as classes presentes na superfície. A estes dados se dá o nome de verdade terrestre. Assim, os obtidos da superfície (verdade terrestre) podem ser utilizados para o treinamento da classificação e parte pode ser deixada para verificar a exatidão da classificação.

Exatidão implica na concordância entre áreas de coberturas terrestres conhecidas (áreas de referência) comparadas com aquelas geradas pelo processo de classificação. Maior a concordância maior a exatidão da classificação. Erros de classificação representam a não identificação da identidade verdadeira de um *pixel*.

Para realizar a avaliação utilizou-se a geração de uma imagem de referência mediante a localização de 150 pontos aleatórios, que quando comparada com a imagem classificada, permitiu a geração da matriz de erros. Desta matriz calculou-se os erros de omissão e comissão, e os índices Kappa e Kappa condicional.

3 Resultados e Discussão

Na classificação supervisionada obteve-se um índice Kappa igual a 0,7780, resultando numa classificação muito boa. Já na classificação não supervisionada o índice Kappa foi de 0,7599, sendo também um resultado muito bom. Era de se esperar que a classificação supervisionada forneça-se um resultado melhor visto que as amostras de treinamento tiveram interferência do analista a priori.

O índice Kappa é estaticamente melhor para avaliar a exatidão da classificação, pois leva em consideração todos os elementos da matriz de erros.

As Figuras 2 e 3 (v.anexo) mostram os mapas temáticos gerados a partir da classificação supervisionada e não supervisionada, respectivamente.

4 Considerações Finais

Ao final deste trabalho pode-se concluir, através dos índices que a classificação supervisionada apresentou melhores resultados quando comparada à classificação não supervisionada, visto que na primeira o analista teve maior controle na classificação, o processo foi balizado por classes pré-definidas pelo usuário e foi possível identificar possíveis imprecisões nas áreas de treinamento antes da classificação, evitando graves prejuízos na classificação.

No entanto, o uso da classificação não supervisionada ainda pode ser recomendado ao usuário, pois esta apresentou índice Kappa muito bom. Quando o usuário não conhece bem a área esse método de classificação pode ser utilizado sem grandes prejuízos.

5 Referências Bibliográficas

ALVES, R. A. L., VERGARA, O. R.: *Identificação de alvos urbanos em imagens Ikonos, aplicando classificação orientada a segmentos.* Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 2573-2580.

CRÓSTA, A. P.: *Processamento digital de imagens de sensoriamento remoto.* Unicamp, 1993. 164p.

ISHIKAWA, M. I.: *Estudo da viabilidade da imagem IKONOS, produto Geo, para aplicações cartográficas urbanas.* 2001, 82p. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente, 2001.

NISHIDA, W.: *Uma rede neural artificial para classificação de imagens multiespectrais de sensoriamento remoto.* Dissertação de Mestrado. Universidade Federal de Santa Catarina, Florianópolis. 1998.

Schowengerdt, R.A.: *Models and methods for image processing*. 2. ed. 1997, 522p.

TISOT, D. A., FORMAGGIO, A. R., GALVÃO, L. S., RENNÓ, C. D.: *Dados Hyperion e ETM+ na classificação de alvos agrícolas com diferentes níveis de distinção espectral*. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 439-446.

Venturieri, A.; Santos, J. R.: *Técnicas de classificação de imagens para análise de cobertura vegetal*. In: Assad, E. D.; Sano, E. E. ed. *Sistemas de informação geográfica: aplicações na agricultura*. 2 ed. Brasília. Embrapa-CPAC, 1998. cap. 2, p. 13-29.

Mapa Temático Resultante da Classificação Supervisionada

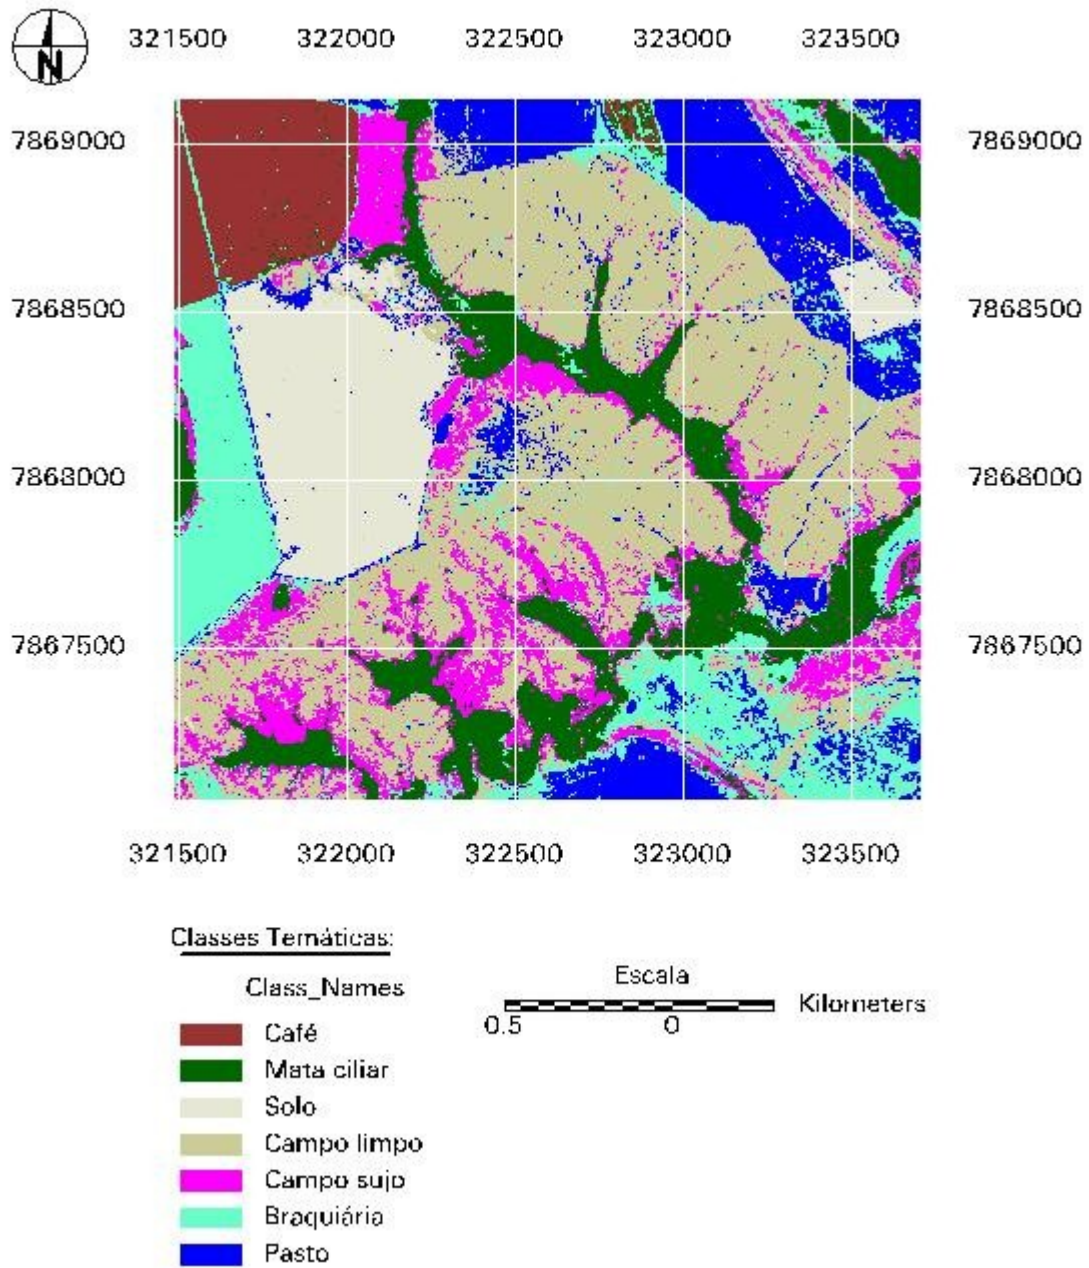


Figura 2 : Resultado da classificação supervisionada

Mapa Temático Resultante da Classificação Não Supervisionada

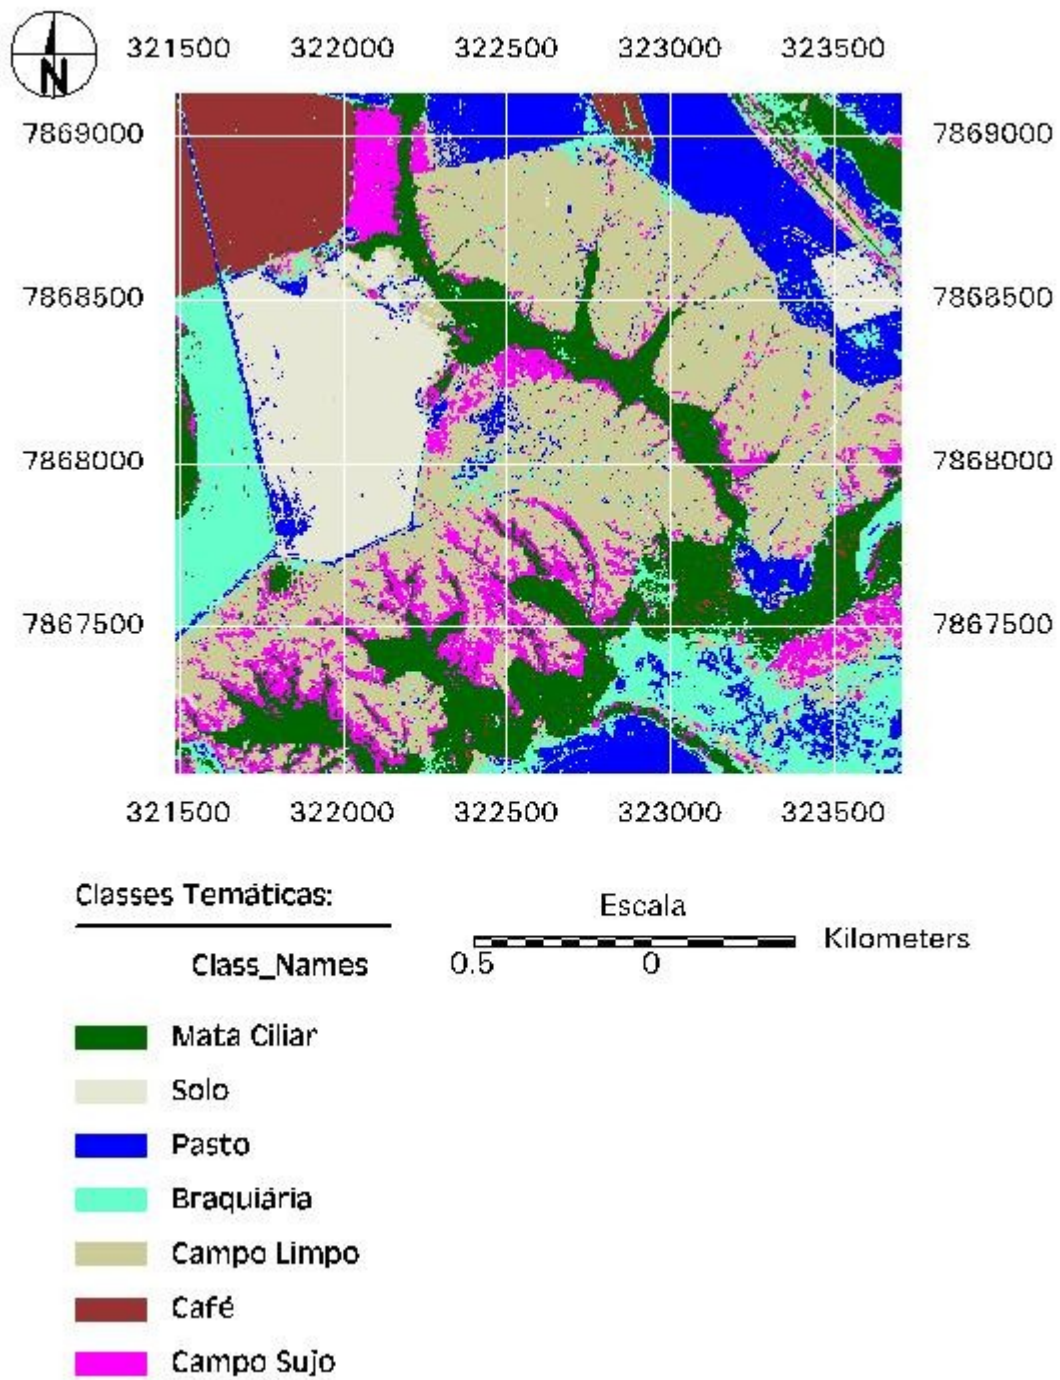


Figura 3 : Resultado da classificação não supervisionada