

INFLUÊNCIA DA DIMENSÃO DOS BLOCOS NA CLASSIFICAÇÃO DE IMAGENS DIGITAIS

Leonardo Rubim Reis¹, Luciano Baião Vieira², Carlos Ernesto Schaefer³, Nerilson Terra Santos⁴,
Francisco Assis Pinto⁵

RESUMO

Para avaliar o efeito de diferentes dimensões de blocos no processo de classificação de imagens, foram obtidas imagens em três alturas diferentes, 4, 20, e 50 m, de uma área experimental de 1.200 m², que continha três blocos com cinco tratamentos cada. Os tratamentos consistiram de cinco preparos distintos de solo. Para obtenção das imagens aéreas, colocou-se uma câmera digital a bordo de um balão. A dimensão dos blocos das imagens utilizadas no processo de classificação para as alturas de 4 e 20 m foram de 50 x 50, 150 x 150 e 250 x 250 pixels e para a altura de 50 m: 50 x 50 e 90 x 90 pixels. As imagens obtidas foram processadas utilizando técnicas de matriz de co-ocorrência de onde foram extraídos oito descritores de textura das imagens, calculados a partir dos blocos das imagens. O bloco com maior dimensão 250 x 250 pixels, apresentou os maiores valores do índice kappa, para altura de 4 e 20 m. Na altura de 50 m o bloco 90 x 90 pixel obteve melhor desempenho.

Palavras chaves: classificação de imagens, câmera digital, blocos.

ABSTRACT

INFLUENCE OF BLOCK DIMENSION ON THE CLASSIFICATION OF DIGITAL IMAGES

To determine the effect of block dimensions on image classification, aerial images from three different heights (4, 20 and 50 m) were obtained in an experimental area of 1.200 m², divided into three blocks, each with five soil preparation methods. The images were obtained with the use of a digital camera in a balloon. The block dimensions for heights of 4 and 20 m were respectively, 50 x 50, 150 x 150 and 250 x 250 pixels and for the height of 50 m, 50 x 50 and 90 x 90 pixels. The images were processed with the use of co-occurrence matrix techniques from which eight texture descriptors, calculated from the image blocks, of the images were extracted for classification. The highest values of the kappa index for 4 and 20 m height were obtained from block of 250 x 250 pixels. For the height of 50 m, the 90 x 90 block gave the best result.

Keywords: image classification, digital camera, block.

Recebido para publicação em 09/10/2008. Aprovado em 20/03/2009

1 Eng. Agrônomo, Ms. Eng. Agrícola, Dr. Eng. Agrícola UFV; Av. Ph.Rolfs, s/n, Departamento de Eng. Agrícola- UFV- MG, Viçosa- MG, Cep: 36570-000, Brasil

2 Eng. Agrônomo, Prof. Adjunto, Departamento de Engenharia Agrícola Av. Ph.Rolfs, s/n, Departamento de Eng.Agrícola- UFV- MG

3 Eng. Agrônomo, Professor Adjunto IV, Universidade Federal de Viçosa, Departamento de Solos. Av P.H. Rolfs sn Centro 36571-000 - Vicosa, MG - Brasil

4 Engenheiro Agrônomo, Prof. Adjunto. Centro de Ciências Exatas e Tecnológicas, Departamento de Informática. Universidade Federal de Viçosa - UFV 36571000 - Viçosa, MG – Brasil

5 Eng.Agrônomo, Professor Adjunto, DEA, UFV, Viçosa (MG), 36570-000. Bolsista do CNPq.

INTRODUÇÃO

Os produtos de sensoriamento remoto, inegavelmente, possuem inestimável utilidade no mapeamento de feições ou de propriedades específicas dos solos, principalmente as agrícolas, que utilizam basicamente as informações superficiais. Para a identificação e análise destas feições, poderiam ser utilizadas técnicas de processamento digital de imagens, destacando-se a classificação, para se obter os padrões espaciais destas feições e o comportamento da sua distribuição espacial (SANTOS et al., 2005).

A classificação de imagens digitais consiste em rotular os pixels de uma cena em classes pré-definidas ou não. O processo de rotulação de cada pixel é feito levando em consideração a proximidade do padrão do pixel, descrito com as n bandas espectrais, com o padrão determinado para uma classe (SWAIN, 1978; LILLESAND e KIEFER, 1994; MATHER, 1999).

Uma imagem pode ser processada sob dois aspectos, o qualitativo, cujo objetivo principal é melhorar a qualidade da imagem para interpretação visual, e o quantitativo, cujo objetivo é extrair conjuntos de informações de regiões específicas da imagem (SCHOWENGERDT, 1983).

Lillesand e Kieffer (2000) definem as técnicas de classificação, como sendo procedimentos utilizados para produzir mapas temáticos a partir da separabilidade de todos os pixels da imagem digital em classes ou temas. Desta forma, esta técnica tem como objetivo associar cada pixel da imagem a uma determinada classe que descreve o tipo de cobertura do terreno.

Em aplicações voltadas ao sensoriamento remoto, técnicas de classificação consistem na fase final do processamento de imagens digitais, obtendo como resultado um conjunto de classes de diferentes padrões espectrais dentro da área de estudo (RODRIGUEZ YI, 1998). Esta técnica pode ser realizada utilizando métodos que agrupam os alvos presentes na imagem por meio do agrupamentos de pixels.

Existem dois métodos de classificação, a classificação supervisionada e a não supervisionada. No presente trabalho foi utilizada a classificação supervisionada.

A classificação supervisionada é o método que se permite interagir com o algoritmo, fornecendo informações como

o número de classes e amostras de áreas conhecidas da imagem para cada classe. Um dos métodos que permite o algoritmo classificar cada “pixel” da imagem é a função discriminante gerada a partir das informações fornecidas pelo usuário.

Segundo Gomes (2001), existem dois tipos principais de classificador: estatístico (não-paramétrico e paramétrico) e conexionista, como exemplo, as redes neurais.

Os classificadores não-paramétricos são mais simples, utilizam a função de distância para determinar as fronteiras de decisão que dividem o espaço de características em sub-espacos, discriminando as classes, os mais comuns são: os classificadores de Distância Euclidiana e de Mahalanobis.

Já os classificadores paramétricos discriminam as classes por meio da estimativa de parâmetros da distribuição dos pontos de cada classe no espaço de características, como a função de densidade de probabilidade, classificador de Bayes.

Os classificadores estatísticos (Equação 1) baseiam-se em regras de classificação matemática, regra de erro mínimo de Bayes, que são formuladas e derivadas em uma estrutura estatística.

$$m \in \Omega_k \text{ se } P(w_k/m) > P(w_j/m) \dots \dots \dots \forall j \neq k \quad (1)$$

em que

m = vetor de característica de um objeto desconhecido;

$P(w_j/m)$ = probabilidade a posteriori de que um objeto com vetor de característica m pertença a classe w_j .

A regra afirma que para minimizar a probabilidade média de erro, um objeto deveria ser classificado como pertencente a classe w_i que maximiza a probabilidade *a posteriori* $P(w_i/m)$. Segundo Jayas et al. (2000), aplicando o teorema de Bayes pode-se obter uma formulação mais prática, conforme apresentado na Equação 2.

$$P(w_i/m) = P(w_i)p(m/w_i) / p(m) \quad (2)$$

Obtendo-se

$$m \in \Omega_k \text{ se } P(w_k)p(m/w_k) > P(w_j)p(m/w_j) \dots \dots \dots \forall j \neq k \quad (3)$$

em que

$P(w_i)$ = probabilidade a priori de que um objeto venha da classe w_i ;

$p(m)$ = função densidade probabilidade de m ;

$p(m/w_i)$ = função densidade probabilidade condicional da classe para m .

O objetivo principal da realização deste trabalho foi analisar a influência da dimensão dos blocos no processo de classificação de imagens coloridas utilizadas no estudo da rugosidade superficial do solo.

MATERIAL E MÉTODOS

O experimento foi realizado em área pertencente à Universidade Federal de Viçosa, no Centro Tecnológico de Desenvolvimento Regional de Viçosa (CENTEV), com acesso pela rodovia entre Viçosa e Teixeras, MG, com coordenadas geográficas 20° 42' 41.12" latitude Sul e 42° 51' 20.98" longitude Oeste. O clima da região, segundo a classificação de Köppen, é do tipo Cwb - clima tropical de altitude com verão chuvoso e temperaturas amenas. A classe de solo é Latossolo Vermelho-Amarelo distrófico.

As avaliações realizadas neste trabalho foram efetuadas em parcelas, com dimensões de 20 m x 3 m, área total de 60 m², demarcadas no solo com auxílio de uma trena e estacas a cada 5 m. Entre cada parcela foi deixado um espaço de 1 m e 5 m entre os blocos. A área de cada bloco foi de 380 m², com área total do experimento de 1.340 m². A área útil das parcelas foi de 15 x 2 m, para eliminar o

efeito de bordadura no processamento.

O experimento foi instalado segundo o delineamento em blocos casualizados com 3 repetições, no qual foram avaliados cinco preparos diferenciados do solo.

Os cinco tipos de preparo do solo avaliados foram:

T1 – Aração, gradagem e enxada rotativa sob baixa rotação;

T2 – Aração, gradagem e enxada rotativa sob média rotação;

T3 – Aração, gradagem e enxada rotativa sob alta rotação;

T4 – Aração e gradagem;

T5 – Aração.

As imagens das unidades experimentais que receberam diferentes tipos de preparo do solo foram obtidas com uma câmera digital. Foram obtidas imagens aéreas das unidades experimentais, nas alturas de 4, 20 e 50 m. Em cada altura, foram obtidas imagens multiespectrais das unidades experimentais (Figura 1).

A resolução espacial em cada altura, considerando-se que a dimensão da imagem em pixel é fixa em todas as alturas de 3072 x 2304 pixels (resolução máxima da câmera utilizada), foi:

- 4 m – resolução espacial de 0,013 m/pixel;
- 20 m – 0,0065 m/pixel;
- 50 m – 0,016 m/pixel;

A resolução espacial indica, de modo geral, a menor dimensão em que um objeto pode ser identificado na imagem a determinada altura.



Figura 1. Fotos tiradas a 4 m (A), 20 m (B) e 50 m (C).

O sistema de aquisição de imagens foi composto de uma câmera digital, marca Fuji, modelo Finepix Z10fd, com sensor CCD de 1/2,5 polegadas, resolução máxima de 7 megapixels (3072 x 2304).

A câmera foi adaptada por meio de um sistema eletrônico para capturar imagens de 5 em 5 segundos. Após a captura, as imagens foram descarregadas no computador para o processamento. O botão mecânico de aquisição de imagem da câmera foi alterado para que fosse acionado de maneira eletrônica.

O sistema controlador desenvolvido tinha a opção de disparo automática ou manual, possuindo dois circuitos, ou bases, um denominado base terra, que fica com o operador em terra, de onde se pode escolher as configurações, manual ou automática, e outro denominando base remota.

Na base terra há um display onde aparecem as opções de controle e as informações de quantas imagens já foram tiradas. A base remota, é responsável pela recepção do sinal e realizar os disparos na câmera. A comunicação entre as duas bases é feita por meio da radiofrequência.

A base terra tem uma interface gráfica exibida em um display LCD 16x02. As opções da base terra são: CONFIGURAR ou INICIAR. Em configurar, há opção de o disparo ser automático ou manual, se automático tem a opção de mudar o tempo de disparo das máquinas, de 1 a 250 segundos, este tempo depende do tempo de resposta da máquina entre os disparos. O disparo é realizado pelo sistema no intervalo de tempo pré-determinado, onde, o disparo no modo manual é feito quando necessário pelo operador.

A base remota possui um programa com o objetivo de identificar a string (seqüência ordenada de caracteres, símbolos, escolhidos a partir de um conjunto pré-determinado) que está sendo enviado pela base terra e executar a rotina de acionamento da câmera.

Para aquisição das imagens aéreas, a câmera foi acoplada a um balão de gás hélio, conforme apresentado na Figura 2.



Figura 2. Suporte da câmera acoplado no balão.

O balão, modelo “*Skyhook Helikite*” é uma combinação de uma pipa (papagaio) com um balão de gás hélio, que aproveita, para o vôo, o empuxo do gás hélio e a força do vento, buscando um vôo eficiente e estável. A altitude e a direção do balão são controladas por meio de uma linha.

Para controle da altitude, foram feitas marcações de 5 em 5 metros, na linha. Em situação totalmente sem vento a altura coincidia com a marca da linha, pois o balão ficava completamente na vertical, com a linha fazendo um ângulo 90° com o solo, contudo, em situação contraária, ou seja, na presença de ventos, a linha apresentava curvatura, o que proporcionava leitura equivocada na altura do balão. Para se evitar erros na altitude, foi criada uma rotina de programação no MatLab® onde se levava em consideração distância conhecida na imagen para calculo da altitude.

A câmera foi configurada na opção de ajuste manual, com a resolução máxima de 3072 x 2304 pixels, tipo de arquivo de imagem *.jpeg, iso 100, equilíbrio de cores (White balance) automático, ajuste Finepix COLOR padrão, estabilização de imagem desligado e o ajuste de compensação de exposição configurado igual a zero (EV).

Para obtenção dos descritores texturais, as imagens foram recortadas em blocos com dimensões de 50 x 50, 90 x 90, 150 x 150 e 250 x 250 pixels, recortados em regiões de interesse (Figura 3). Estes blocos foram utilizados para montar a matriz de co-ocorrência e calcular os descritores texturais utilizados na classificação das 5 classes de rugosidade. Nas imagens com altura de 50 m, o tamanho dos blocos foi 50 x 50 e 90 x 90 pixels, e na altura de 100 m apenas 50 x 50 pixels, isto foi necessário para se evitar as bordaduras da parcela na imagem durante o processamento, sendo feito em ambas as imagens, coloridas e infravermelhas.

Todo o processamento foi feito em programa Matlab®, por meio de rotina de corte, onde em um primeiro instante clicava-se na região de interesse da imagem, as coordenadas dos pontos na imagem eram armazenados e outra rotina executava os cortes dos blocos, ao todo 100 blocos por imagem, totalizando 500 blocos.

De cada um desses sub-blocos foi gerado uma matriz de co-ocorrência, da qual foram obtidos os descritores texturais durante a fase de processamento. Para cada combinação dos fatores estudados, foram recortados 100 sub-blocos de cada classe.

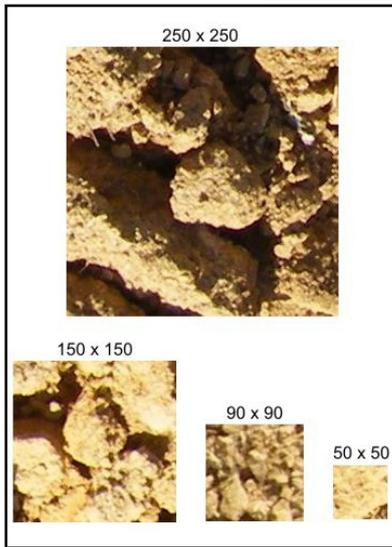


Figura 3. Tamanhos dos blocos retirados das fotografias visando o processamento das imagens.

Após os cortes dos 100 blocos de cada classe nas diferentes alturas, foi utilizada a técnica de análise textural,

utilizando a matriz de co-ocorrência para o cálculo dos descritores. Foi calculada a matriz de co-ocorrência para cada um dos blocos recortados.

Para a utilização da matriz de co-ocorrência nos cálculos dos descritores texturais, Quadro 1, foi preciso realizar a normalização da matriz, conforme apresentado na Equação 4.

$$p(i, j) = \frac{P(i, j)}{\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} P(i, j)} \tag{4}$$

em que

$p(i, j)$ = matriz de co-ocorrência normalizada;

i = número da linha;

j = número da coluna;

$P(i, j)$ = elementos da matriz de co-ocorrência;

Ng = número total de níveis de cinza.

Quadro 1. Descritores utilizados na classificação (HARALICK, 1973).

Descritores	
Momento angular	$C_1 = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} [p(i, j)]^2$
Média	$C_2 = \sum_{i=0}^{Ng-1} i * p_x(i)$
Variância	$C_3 = \sum_{i=0}^{Ng-1} (i - C_2)^2 p_x(i)$
Entropia	$C_4 = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} p(i, j) \ln [p(i, j)]$
Correlação	$C_5 = \frac{[\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} ij p(i, j)] - C_2^2}{C_3}$
Momento do produto	$C_6 = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} (i - C_2)(j - C_2) p(i, j)$
Momento inverso da diferença	$C_7 = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} \frac{p(i, j)}{1 + (i - j)^2}$
Medidas de correlação	$C_8 = \frac{C_2 - HXY1}{HX}$ $HX = - \sum_{i=0}^{Ng-1} p_x(i) \ln [p_x(i)]$ $HXY1 = - \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} p(i, j) \ln [p_x(i) p_x(j)]$

Foram utilizadas todas as combinações dos descritores possíveis, totalizando 255 combinações, na formação do vetor característica para serem submetidos a um classificador. Todos os cálculos foram realizados segundo rotina elaborada em programa específico, MatLab e os dados foram salvos em planilhas eletrônicas, com dimensão de 500 linhas x 9 colunas, sendo que na primeira coluna havia os números das classes, de 1 a 5, e nas outras 8 colunas os valores dos descritores. Para cada classe havia um total de 100 linhas, totalizando 500 linhas.

Para saber qual foi a dimensão dos blocos que apresentou melhor desempenho no processo de classificação das imagens, foi avaliado o classificador por meio da validação cruzada e pelo índice Kappa. O classificador que foi utilizado no processo foi o classificador Bayesiano que se baseia na Teoria de decisão Bayesiana sob densidade normal.

A probabilidade do indivíduo x ser classificado na classe W_j , $P(W_j|x)$, pode ser estimada por meio da função de decisão do classificador, que é expressa na Equação 5 (GONZALEZ e WOODS, 2000):

$$d_j(x) = \ln P(W_j) - \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (5)$$

em que

C_j = matriz de covariância da classe j ;

x = vetor de característica das classes;

m_j = vetor de médias das características da classe j ;

T = símbolo da matriz transposta;

$P(W_j)$ = probabilidade de ocorrência da classe W_j ;

n = dimensão dos vetores de descritores.

Dessa maneira, têm-se uma função discriminante para cada uma das cinco classes de rugosidade superficial do solo. Assim, para cada vetor característica inserido no classificador, foi calculado o valor das funções discriminantes $d_j(x)$, atribuindo-se o vetor característica à classe que apresentasse o maior valor da função. Ao final da classificação era gerado um arquivo em formato *.xls, planilha eletrônica, com as seguintes informações: descritores utilizados na formação do vetor característica; a variância do índice kappa; o valor do índice kappa e a matriz de classificação.

Para estimar o erro do classificador, foi utilizado a validação cruzada e o coeficiente Kappa. A taxa de erro da classificação final é dada conforme apresentado na Equação 6:

$$E = \frac{1}{n} \sum_{i=1}^n e(i) \quad (6)$$

em que

E = taxa de erro;

n = número de amostras;

$e(i)$ = erro em cada interação, igual a 0 para classificações corretas e 1 para erros.

A matriz de erros é um arranjo quadrado em linhas e colunas e que expressa o número de amostras atribuídas às diferentes categorias verificadas no campo. As colunas usualmente representam os dados de referência, enquanto as linhas indicam os resultados da classificação (CONGALTON, 1991). Segundo Hudson & Ramm (1987), o cálculo do coeficiente Kappa será efetuado por meio da Equação 7.

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (7)$$

Em que

\hat{K} = estimativa do coeficiente Kappa;

x_{ii} = valor na linha i e coluna i da matriz de erros;

$x_{i\oplus}$ = total da linha i ;

$x_{\oplus i}$ = total da coluna i ;

n = número total de amostras, 100; e

C = número total de classes, 5.

Os dados apresentados no Quadro 2 serviram como referência para comparar os índices kappas, escolhidos pelo teste Z , em cada classificação. Após a escolha dos maiores índices Kappa foi utilizado o teste estatístico (Z) para a comparação do desempenho dos classificadores gerados a partir das diferentes dimensões dos blocos.

Quadro 2. Valores do índice Kappa.

Valor	Coefficiente Kappa qualitativo
< 0,01	Péssima
0,01 – 0,20	Ruim
0,21 – 0,40	Razoável
0,41 – 0,60	Boa
0,61 – 0,80	Muito boa
0,81 – 1,0	Excelente

Para testar a diferença entre os coeficientes Kappa calculados, ao nível de significância de 5%, foi utilizado o teste Z (CONGALTON & MEAD, 1983) de acordo com a Equação 8.

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (8)$$

em que

- Z = valor de Z calculado;
- \hat{K}_1 = coeficiente kappa do classificador 1;
- \hat{K}_2 = coeficiente kappa do classificador 2;
- $\text{var}(\hat{K}_1)$ = variância do coeficiente kappa do classificador 1;
- $\text{var}(\hat{K}_2)$ = variância do coeficiente kappa do classificador 2.

Para determinar a variância de grandes amostras do coeficiente kappa, foi utilizada a Equação 9 (BISHOP et al., 1975, citados por HUDSON e RAMM, 1987):

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_2-\theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4-4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (9)$$

Quadro 3. Resultados da Exatidão Global (E.G) valores kappa para os diferentes blocos para cada altura testada.

Altura	Bloco	Índice Kappa	EG%	Altura	Bloco	Índice Kappa	EG%	Altura	Bloco	Índice Kappa	EG%
4 m	50x50	0.473 a	58,0	20 m	50x50	0.7825 a	82,6	50 m	50x50	0.8425 a	87,4
	150x150	0.738 b	79,0		150x150	0.995 b	99,6		90x90	0.9875 b	99,0
	250x250	0.965 c	97,0		250x250	1,0 b	100				

1

1 Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste Z, em nível de 5% de probabilidade.

em que

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_i$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_i \otimes x_{\oplus i}$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_i (x_{i \oplus} + x_{\oplus i})$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_j (x_{j \oplus} + x_{\oplus j})^2$$

O melhor classificador foi determinado por meio do maior valor Kappa diferente, significativamente em nível de 5% de probabilidade, pelo teste Z.

RESULTADOS E DISCUSSÃO

No Quadro 3, estão apresentados os índices kappa e a exatidão global para as imagens nas respectivas alturas utilizando-se diferentes tamanhos de blocos. De uma maneira geral, o bloco com dimensão de 50 x 50 pixels apresentou menores valores do índice kappa em todas as alturas trabalhadas (4, 20 e 50 m).

Na altura de 4 m, a classificação não foi satisfatória, uma vez que os valores do índice kappa estiveram, na maioria das vezes, abaixo de 0,50, para o bloco com dimensão de 50 x 50 pixels. Isto pode ser devido ao fato de que blocos com dimensões maiores abranjam maior região, contendo mais informações das classes estudadas, por outro lado podem também conter informações que não sejam de interesse no estudo, como as bordaduras das parcelas.

Observa-se que, exceto para a altura de 20 metros, em cada uma das alturas do balão em que foram retiradas as imagens, foram detectadas diferenças significativas entre os diferentes tamanhos de blocos. A escolha do tamanho dos blocos, 150 x 150 ou 250 x 250 pixels, neste caso, seria pelo tempo e o uso de memória do sistema para o processamento. O tempo de processamento gasto para os blocos 150 x 150 pixels foi de 503 segundos (aproximadamente 8' 38'') e para os blocos 250 x 250 pixels foi de 507 segundos (aproximadamente 8' 45''), diferença de 0,07 milésimos de segundo, relativamente pequena, optou-se, então, pelo tamanho de bloco que apresentou maior exatidão global, no caso 250 x 250 pixels, com exatidão global igual a 100%.

Em relação aos blocos 50 x 50 e 90 x 90 pixels, para imagens a 50 m de altura, houve diferença estatística entre os valores do índice kappa, sendo que no bloco de 90 x 90 foi obtido maior valor, 0,98, exatidão global de 99% e tempo de processamento de 508 segundos (aproximadamente 8' 46'') e nos blocos de 50 x 50 pixels, o índice kappa foi de 0,84 e tempo de processamento foi de 509 segundos (aproximadamente 8' 48'').

Os maiores valores de índice kappa, com imagens captadas a 4 m de altura, foram obtidos com a dimensão de bloco de 250 x 250 pixels (Figura 4).

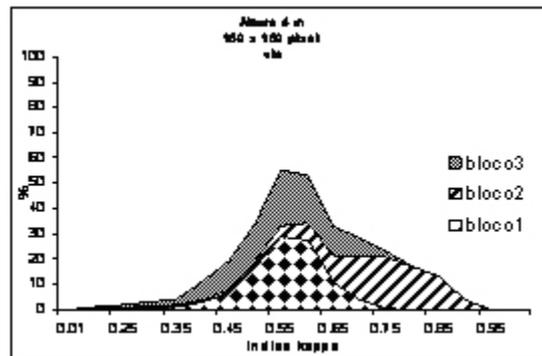
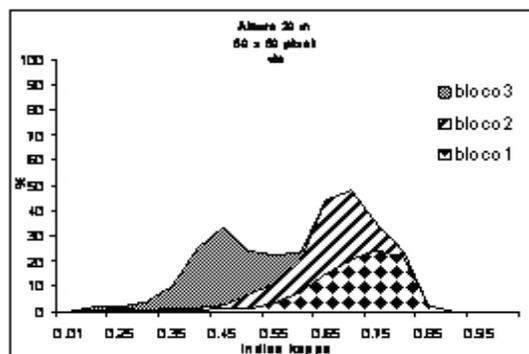
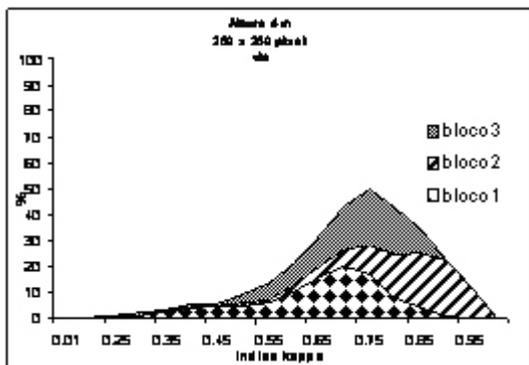
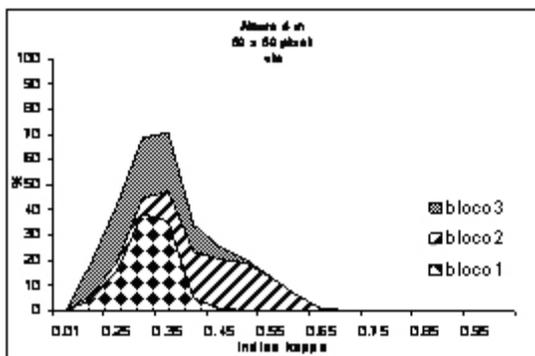


Figura 4. Frequência dos valores do índice kappa dos blocos 50 x 50, 150 x 150 e 250 x 250, pixel na altura de 4 m.

Em relação aos blocos 50 x 50 e 90 x 90 pixels, para imagens a 50 m de altura, houve diferença estatística entre eles, sendo que o bloco de 90 x 90 apresentou exatidão global de 99%, sendo o tempo de processamento semelhante ao obtido no processamento dos blocos de 50 x 50 pixels.

Percebe-se que, com o aumento da dimensão dos blocos, houve tendência de aumento no índice kappa, ou seja, há melhora na exatidão da classificação, lembrando que um índice entre 0,81 a 1,0 é considerado excelente. O mesmo comportamento da influência da dimensão dos blocos na classificação foi descrito por Tang et al. (1999), que utilizaram três diferentes tamanhos de sub-blocos (9 x 9, 13 x 13 e 17 x 17 pixels) e verificaram que os mesmos influenciaram no tempo de processamento e na acurácia da classificação, sendo que o bloco maior foi o que proporcionou os melhores resultados.

Para a altura de 20 m, houve comportamento semelhante ao ocorrido nas imagens com 4 m de altura, o aumento da dimensão dos blocos proporcionou tendência de aumento nos índices kappas, conforme pode ser observado na Figura 5.



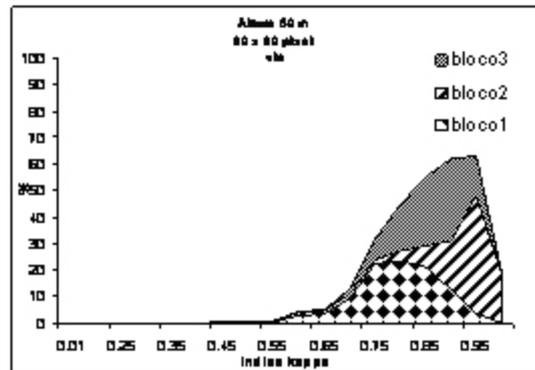
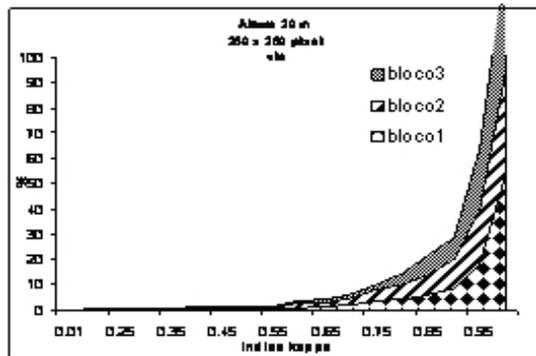
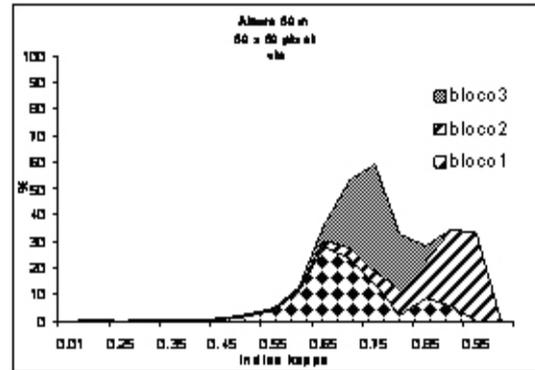
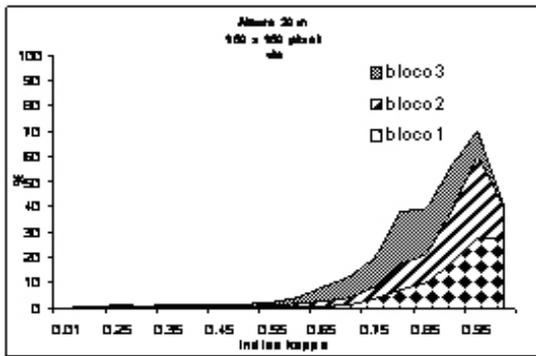


Figura 5. Frequência dos valores do índice kappa dos blocos 50 x 50, 150 x 150 e 250 x 250 pixels, na altura de 20 m.

Figura 6. Frequência dos valores do índice kappa dos blocos 50 x 50, 90 x 90 pixel, altura de 50 m.

Os blocos 150 x 150 e 250 x 250 pixels, na altura de 20 m, proporcionaram obtenção da maioria dos valores acima de 0,85, porém o bloco 250 x 250 pixels proporcionou maior tendência na concentração dos índices kappa entre 0,95 e 1,00, índices que são considerados, para efeito de classificação, excelentes. Nos blocos com dimensões de 150 x 150 pixels, 55,89% dos valores apresentaram resultados superiores a 0,90 e nos blocos 250 x 250 foram 77,15% os valores acima deste. Em relação ao bloco 50 x 50 pixels, na altura de 50 m, comparando com o bloco 90 x 90, percebe-se maior amplitude nos valores dos índices, por outro lado, no bloco 90 x 90 pixels houve maior concentração dos valores acima de 0,85 (Figura 6).

Nos blocos com dimensões pequenas e nas menores alturas, o cálculo dos descritores texturais para determinada classe ficou restrito ao objeto representado na imagem. No caso das imagens adquiridas a 4 m, tanto o bloco de 50 x 50 como de 150 x 150 pixels, apresentaram parte de um ou poucos torrões da parcela, sendo que os descritores texturais serão calculados com base apenas nesses torrões, não sendo obtidas informações de toda a classe.

O efeito do bloco 50 x 50 na altura de 20 m foi o mesmo ocorrido na altura de 4 m, mas os blocos 150 x 150 e 250 x 250 pixels apresentaram maior área da parcela, ou seja, tem maior representação de determinada classe, se s resultados forem comparados com os obtidos nos blocos com mesma dimensão, para altura de 4 m.

Orlando (2003) testou três diferentes tamanhos de blocos (17 x 17, 34 x 34 e 68 x 68 pixels) para classificação de plantas daninhas e concluiu que os melhores valores da exatidão global ocorreram para o tamanho de bloco 68 x 68 pixels, confirmando a melhora no processo de classificação de imagens com o aumento na dimensão dos blocos. Segundo o mesmo autor, blocos pequenos tendem a representar a textura da folha e tamanhos de bloco maior, dependendo da resolução da câmera, normalmente, representam a textura do dossel.

O mesmo raciocínio pode ser feito para os blocos utilizados no estudo da rugosidade superficial do solo, blocos com dimensões pequenas tendem a representar a textura de um torrão e blocos com dimensões maiores e maior altura de aquisição das imagens, representam maior parte da área em estudo.

Comparando os blocos de 50 x 50 (C), a altura de 4 e 20 m da Figura 7, com os blocos de 50 x 50 (A), a 50 m da mesma Figura 7, percebe-se maior número de torrões presentes na área do bloco, o mesmo

ocorrendo com o bloco de 90 x 90 pixels, reforçando que, com o aumento da dimensão dos blocos, se obtém informações de textura da classe e não de pequenos torrões.

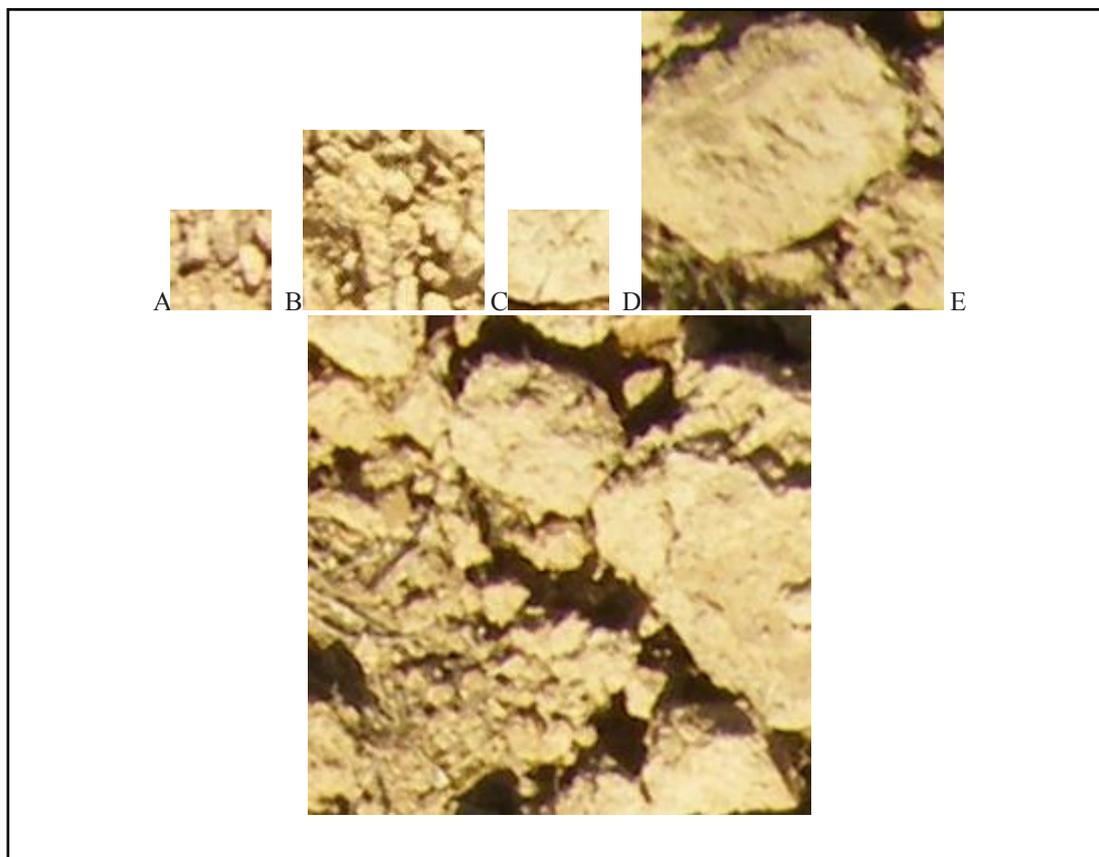


Figura 7. Diferentes tamanhos de blocos: A - 50 x 50; B - 90 x 90 pixels, para imagens a 50 m, e C - 50 x 50; D - 150 x 150; e E - 250 x 250 pixels, para imagens adquiridas a 4 m de altura.

De acordo com Marceau et al. (1990), 90% da variabilidade na precisão de classificação usando textura depende do tamanho do bloco usado para calcular a textura, enquanto os algoritmos particulares de textura determinam somente 10%. Essa é uma particularidade importante, pois, a maioria dos estudos envolvendo textura aborda o desenvolvimento e a avaliação de algoritmos, sem se preocupar com o efeito do tamanho da janela. Segundo Nascimento (2003), blocos de dimensões menores não capturam o padrão particular da maioria das classes, enquanto blocos maiores podem incluir pixels de mais do que uma classe, resultando em classificações menos precisas. O tamanho ideal do bloco é aquele que produz a menor variabilidade na textura.

CONCLUSÕES

- O aumento na dimensão dos blocos das imagens proporciona melhora significativa no processo de

classificação das imagens;

- Em blocos com dimensão de 50 x 50 pixels, na altura de 4 m, foram obtidos baixos desempenhos no processo de classificação.

REFERÊNCIA BIBLIOGRÁFICA

CONGALTON, R.G. **A review of assessing the accuracy of classifications of remotely sensed data.** Remote sensing of environment, New York, n.37, p.35-46, 1991.

GOMES, O.F.M. **Processamento e análise de imagens aplicadas à caracterização automática de materiais.** Dissertação Mestrado. Departamento de Ciências de Materiais e Metalúrgica PUC/Rio, 2001.

GONZALES, R.C., WOODS, R.E. **Processamento de**

imagens digitais. Editora Edgard Blücher Ltda, São Paulo. 509p, 2000.

HARALICK, R.M. **Texture features for image classification.** In: *IEEE Transactions on Systems, Man and Cybernetics*. SMC-3, nº 6. 1973.

HUDSON, W.D., RAMM, C.W. **Correct formulation of the kappa coefficient of agreement.** *Photogrammetric engineering & remote sensing*. Bethesda, v.53 n.4, p.421-422, 1987.

JAYAS, D.S, PALIWAL, J, VISEN, N.S. **Multi-layer neural networks for image analysis of agricultural products.** *Journal Agricultural Engineering Research*, Silsoe, v.77, n.2, p.119-128, 2000.

LILLESAND, T.M.; KIEFER, R.W. **Remote sensing and image interpretation.** New York: John Wiley and Sons, 1994. 750 p.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and image interpretation.** 3. ed. New York, John Wiley & Sons, 2000. 724 p.

MATHER, P.M. **Computer procesing of remotely-sensed images: an introduction.** West Succex, John Wiley and Sons, 1999. 292p.

MARCEAU, D.J., HOWARTH, P.J., DUBOIS, J.M.M. e GRATTON, D.J. **Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT imagery.** *IEEE Transactions on Geoscience and Remote Sensing*, V. Março 1990, 513–519, 1990

NASCIMENTO, J.P.R. **Análise e classificação de imagens baseadas em características de textura**

utilizando matrizes de co-ocorrência, Dissertação Mestrado, Universidade Federal do Paraná, 2003.

ORLANDO, R.C., **Sistema de visão artificial para discriminação entre plantas daninhas e milho.** Tese Doutorado. Viçosa, UFV, 2003.

RODRIGUEZ Y,J.L. **Mapeamento e monitoramento da vegetação do Estado do Mato Grosso através de imagens AVHRR-NOAA.** 135p. (INPE-6816-TDI/638). Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, 1998.

SWAIN, P.H. **Fundamentals of pattern recognition in remote sensing.** In: Swain, P. H.; Davis, S.H. *Remote sensing: a quantitative approach*. 1. ed. EUA, McGraw-Hill, 1978, cap.3, p.136-187.

SCHOWENGERDT, R.A. **Techniques for image processing and classification in remote sensing.** Academic Press, 1983. 249p.

SANTOS, R.L., QUINTANILHA, J.A., FUKUMORI, I. **Os solos e o sensoriamento remoto: o uso de imagens Landsat 7 ETM para mapeamento dos horizontes coesos dos Tabuleiros Costeiros da Bahia.** In: XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, Goiânia, INPE, 16-21 abril 2005, p.2749-2757.

TANG, L., TIAN, L.F., STEWARD, B.L., REID, J.F. **Texture-based weed classification using Gabor Wavelets and Neural Network for real-time selective herbicide applications.** ASAE/CSAE-SCGR Annual International Meeting. Toronto, Ontario. Paper nº 993036, 10 p, 1999.