

LEONARDO RUBIM REIS

**AVALIAÇÃO DA RUGOSIDADE SUPERFICIAL DO SOLO UTILIZANDO
TÉCNICAS DE SENSORIAMENTO REMOTO E ANÁLISE DE IMAGENS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2009

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

R375a
2009

Reis, Leonardo Rubim, 1975-

Avaliação da rugosidade superficial do solo utilizando técnicas de sensoriamento remoto e análise de imagens / Leonardo Rubim Reis – Viçosa, MG, 2009. xvii, 121f.: il.; 29cm.

Inclui apêndice.

Orientador: Luciano Baião Vieira.

Tese (doutorado) - Universidade Federal de Viçosa.

Referências bibliográficas: f. 89-98

1. Solo. 2. Morfologia. 3. Sensoriamento remoto. 4. Imagens - Processamento. 5. Testes de interpretação de imagens. 6. Física do solo. 7. Solos - Erosão
I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 631.4

LEONARDO RUBIM REIS

**AVALIAÇÃO DA RUGOSIDADE SUPERFICIAL DO SOLO UTILIZANDO
TÉCNICAS DE SENSORIAMENTO REMOTO E ANÁLISE DE IMAGENS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 20 de fevereiro de 2009.

 _____ Julião Soares de Souza Lima	 _____ Denilson Eduardo Rodrigues
 _____ Haroldo Carlos Fernandes	 _____ Nerilson Terra Santos (Coorientador)
 _____ Luciano Baião Vieira (Orientador)	

A meus pais
José Reginaldo Figueiredo Reis
e Eloísa Rubim Reis (*in memoriam*).

Às minhas irmãs
Tatiana Rubim Reis,
Luciana Rubim Reis
e Adriana Rubim Reis.

À minha amada e querida filha
Alexia V. R. Reis.

DEDICO COM AMOR.

Para
Aléxia, Reginaldo.

OFEREÇO.

AGRADECIMENTOS

Ao meu pai José Reginaldo, pelo apoio, pelo incentivo de continuar mesmo nas horas de grandes dificuldades, pelo amor e pelo carinho.

Às minhas irmãs Tati, Lu e Dri, pela amizade, pelo amor e pelo incentivo mesmo de longe.

À minha filha “Baixinha” Aléxia, pela fonte de inspiração e pelo amor incondicional.

À minha saudosa mãe Eloísa, que, mesmo distante, me acompanha e se alegra com minhas vitórias.

Aos demais familiares que, de maneira direta ou indireta, colaboraram para a realização deste sonho.

À Universidade Federal de Viçosa, pela oportunidade oferecida para a realização desta pesquisa.

À CAPES, pelo auxílio financeiro ao longo do curso.

À FAPEMIG, por ter acreditado e financiado o projeto.

Ao professor Dr. Luciano Baião Vieira, pela orientação, pela amizade e pelos ensinamentos.

Ao professor Dr. Carlos Ernesto Gonçalves Reynaud Schaefer, pelos conselhos, pelos conhecimentos adquiridos e pela oportunidade.

Ao professor Dr. Nerilson Terra Santos, pela orientação na parte de estatística e pela amizade.

Ao professor Dr. Francisco de Assis de Carvalho Pinto, pelos conhecimentos que me foram repassados e pelos conselhos.

A Danilo, Vantuil, Geraldão e Marcelo, funcionários do Laboratório de Mecanização Agrícola, pela execução dos trabalhos na montagem do experimento.

Aos amigos de curso, em especial a Wagner, Ariston, vulgo “Codó”, pela companhia e pela ajuda durante os trabalhos de campo.

Ao amigo Toninho, pela ajuda e pelos conselhos sobre o programa de processamento de imagens utilizado neste trabalho.

Aos amigos Denílson e Renan, que ajudaram a “destruir” algumas câmeras e a desenvolver o sistema eletrônico.

Aos colegas da pós-graduação pelos momentos de solidariedade, pela amizade e pela alegria, compartilhados dentro e fora da universidade: Walter, Toninho, Ronaldo, Wagner, Gerson “Buda”, Francelino, Douglas, Willian, Alisson “Bigas”, Geice, Danilo, Murilo, Amanda, Paulinha, Diogo, Gislaine, Selminha, Mário, Henrique, Lorena, Frederico, Ariston e Marcos “Barba”.

Aos amigos da república, Arthur, Dawson e Diogo, pelos momentos de convivência e amizade, em especial ao Arthur, pela ajuda na primeira fase dos experimentos em campo.

À secretária do Programa de Pós-Graduação da Engenharia Agrícola, Edna, pela atenção, paciência e amizade. Também agradeço Renato e Marcos, funcionários do DEA.

BIOGRAFIA

LEONARDO RUBIM REIS, filho de José Reginaldo Figueiredo Reis e Eloísa Rubim Reis, nasceu em São Sebastião do Paraíso, MG, em 21 de março de 1975.

Em março de 1999, formou-se em Engenharia Agrônômica pela Universidade Federal de Viçosa.

De abril a novembro de 1999, foi bolsista do Consórcio Nacional do Café.

Em novembro de 1999, foi contratado pela EMATER-MG, onde atuou nas áreas de cafeicultura, meio ambiente e extensão rural, permanecendo na empresa até meados de setembro de 2002.

Em setembro de 2002, iniciou o curso de Mestrado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, submetendo-se à defesa de dissertação em 11 de fevereiro de 2005.

Em março de 2005, ingressou no Doutorado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, concluindo-o em 20 de fevereiro de 2009.

Em janeiro de 2009, foi aprovado no concurso para professor substituto no Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais, campus de Machado.

SUMÁRIO

	Página
LISTA DE TABELAS	ix
LISTA DE FIGURAS	xi
RESUMO	xiv
ABSTRACT	xvi
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	4
2.1. Rugosidade superficial do solo	4
2.2. Sensoriamento remoto	7
2.3. Uso de câmeras digitais no sensoriamento remoto	15
2.4. Classificação de imagens	21
2.5. Análise de textura	25
2.6. Matriz de co-ocorrência	27
3. MATERIAL E MÉTODOS	30
3.1. Análises laboratoriais	33

	Página
3.1.1. Caracterização física e agregação (via úmida)	33
3.1.2. Caracterização química	33
3.2. Índice de rugosidade	34
3.3. Sistema de aquisição de imagens	36
3.4. Altura do balão	43
3.5. Tamanho dos blocos das imagens	45
3.6. Estudo das características do solo utilizando processamento de imagem digital	47
3.6.1. Melhores parâmetros para a classificação	47
3.6.2. Cálculo dos descritores	47
3.6.3. Classificação	50
3.6.4. Avaliação dos classificadores	51
3.7. Correlação do índice de rugosidade com descritores textuais ..	54
4. RESULTADOS E DISCUSSÃO	55
4.1. Análise de solo	55
4.2. Índice de rugosidade	58
4.3. Avaliação do sistema de aquisição de imagens	60
4.4. Tamanho dos blocos da imagem	61
4.5. Ângulos da matriz de co-ocorrência	69
4.6. Avaliação dos descritores	74
4.6.1. Avaliação das combinações dos descritores nas diferentes bandas de imagens coloridas e infravermelhas	79
4.7. Correlação do índice de rugosidade superficial do solo com os descritores texturais da imagem	86
5. CONCLUSÕES	88

	Página
REFERÊNCIAS	89
APÊNDICES	99
APÊNDICE A – Código fonte para o cálculo do índice de rugosidade superficial do solo	100
APÊNDICE B – Código fonte para recorte dos blocos das imagens	102
APÊNDICE C – Código fonte para a montagem da matriz de co-ocorrência e cálculo dos descritores textuais	104
APÊNDICE D	112
APÊNDICE E – Código fonte do algoritmo de classificação	114
APÊNDICE F	118
APÊNDICE G	119
APÊNDICE H	120
APÊNDICE I	121

LISTA DE TABELAS

		Página
1	Principais missões de sensoriamento remoto orbital em operação	8
2	Preços de aquisição de imagens pelo satélite IKONOS	10
3	Preços de imagens que não estão contidas no catálogo <i>on line</i>	10
4	Comparação entre os diferentes tipos de plataformas aéreas .	16
5	Valores do índice kappa	53
6	Análise de textura das parcelas experimentais	56
7	Análise química das parcelas experimentais	57
8	ANOVA	58
9	Análise dos índices de rugosidade pelo teste Tukey	59
10	Exatidão global (EG), índices kappa obtidos em diferentes tamanhos de blocos e alturas do balão	61
11	Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 4 m	70
12	Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 20 m	70

	Página
13	Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 50 m 71
14	Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 100 m 73
15	Dados estatísticos do índice kappa para os blocos de imagem adquirida a diferentes alturas 77
16	Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas, altura da câmera a 4 m . 80
17	Resultados da exatidão global (EG), valores kappa para as bandas das imagens coloridas, altura da câmera a 4 m 80
18	Representação da matriz de confusão: A – matriz de classificação para IV G e B – matriz de classificação para banda B 82
19	Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas e coloridas, altura da câmera a 20 m 82
20	Matriz de confusão para valor de kappa igual a 1,0 nas bandas IV R, IV B e B, para altura de 20 m 83
21	Resultados da exatidão global (EG), valores do índice kappa para as bandas das imagens infravermelhas e coloridas, altura da câmera a 50 m 84
22	Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas e coloridas, altura da câmera a 100 m 85
23	Valores dos coeficientes de correlação de Pearson, entre índice de rugosidade e os descritores texturais 86
1D	Exemplo de uma matriz com os valores dos descritores texturais 112
1F	Exemplo de parte da planilha gerada pelo classificador, com as combinações dos descritores utilizados, exatidão global índice kappa, variância do índice kappa e a matriz de classificação 118

LISTA DE FIGURAS

		Página
1	Balão modelo "SKYHOOK HELIKITES"	12
2	Balão e o sistema de controle	13
3	Comparação da altura de trabalho do balão com aeromodelos	14
4	Detalhe do pêndulo com o local da câmera	14
5	Matriz de co-ocorrência mostrando as componentes do vetor d	27
6	Ângulos da matriz de co-ocorrência	29
7	Foto aérea da área experimental, mostrando os números das parcelas e seus respectivos tratamentos: P (parcela) e T (tratamento)	31
8	Vista lateral do bloco 1 com os cinco tratamentos	31
9	Imagem dos implementos utilizados na fase inicial do experimento: (a) arado de aivecas; (b) grade; e (c) enxada rotativa, com tampa fechada	32
10	Perfilômetro de hastes e suporte com a câmera digital (a); quadro de 1 m ² (b); e imagem obtida pela câmera colocada no suporte (c)	35

11	Câmera utilizada para captar imagens coloridas (a); e câmera adaptada para captar imagem infravermelha com filtro marca B+W (b)	37
12	Câmera aberta mostrando a retirada do filtro colorido	38
13	Resposta espectral típica de um CCD	39
14	Curva de resposta espectral do filtro B+W 093	39
15	Sistema eletrônico para acionamento das câmeras: base remota (a); base terra (b); e detalhe da adaptação do botão de disparo (c)	40
16	Suporte das câmeras acoplado no balão e detalhe da parte inferior do suporte mostrando a lente das câmeras, colorida e infravermelho	42
17	Balão modelo "SKYHOOK HELIKITE"	42
18	Foto colorida a 4 m (a1); foto infravermelha a 4 m (a2); foto colorida a 20 m (b1); e foto infravermelha a 20 m (b2)	44
19	Fotos a 50 m: uma colorida e duas infravermelha (c); fotos a 100 m: uma colorida e duas infravermelha (d)	45
20	Tamanho dos blocos, em pixel, utilizados para a montagem da matriz de co-ocorrência	46
21	Imagens obtidas simultaneamente da mesma área, altura de 20 m: colorida (a); e infravermelho (b)	60
22	Gráficos de freqüência dos valores do índice kappa dos blocos 50x50, 150x150 e 250x250, pixel na altura de 4 m, das imagens infravermelho (iv) e coloridas (vis)	63
23	Gráficos de freqüência dos valores do índice kappa dos blocos 50x50, 150x150 e 250x250, pixel na altura de 20 m, da imagens infravermelho (iv) e coloridas (vis)	64
24	Gráficos de freqüência dos valores do índice kappa dos blocos 50x50, 90x90, altura de 50 m e 50x50 pixel na altura de 100 m, das imagens infravermelho (iv) e coloridas (vis)	66
25	Diferentes tamanhos de blocos: imagem colorida a 4 m de altura (a, b, c); imagem infravermelha a 20 m (d, e, f); 50x50 pixel (a, d); 150x150 pixel (b, e); e 250x250 pixel (c, f)	67

26	Exemplos de blocos 50x50 pixel, 90x90 pixel para imagens a 50 m (a, b) e bloco 50x50 pixel para imagens a 100 m (c)	68
27	Gráficos de frequência dos valores do índice kappa dos blocos, nas diferentes orientações, para as alturas de 4, 20, 50 e 100 m	73
28	Exemplo das bandas de uma imagem: banda R (a); banda G (b); banda B (c); imagem colorida (d); banda IV R (e); banda IV G (f); banda IV B (g); e imagem infravermelha (h)	75
29	Gráfico de frequência do índice kappa, obtido com a avaliação dos descritores para as diferentes bandas e alturas, 4 e 20 m	78
30	Gráfico de frequência do índice kappa, obtido com a avaliação dos descritores para as diferentes bandas e alturas, 50 e 100 m	79
1G	Fluxograma do circuito da base terra	119
1H	Fluxograma do circuito da base renda	120
1I	Esquema do circuito eletrônico da base remota e base terra ..	121

RESUMO

REIS, Leonardo Rubim, D.Sc., Universidade Federal de Viçosa, fevereiro de 2009. **Avaliação da rugosidade superficial do solo utilizando técnicas de sensoriamento remoto e análise de imagens.** Orientador: Luciano Baião Vieira. Coorientadores: Nerilson Terra Santos e Carlos Ernesto Gonçalves Reynaud Schaefer.

Para realizar o estudo de rugosidade superficial do solo por meio de técnicas de sensoriamento remoto, foi feito em uma área de 1.200 m², três blocos com cinco tratamentos cada, sendo as dimensões da parcela de 20 m de comprimento por 3,0 m de largura e 1,0 entre cada parcela, cada bloco com uma área de 20 x 19 m. Em cada bloco foi realizado o sorteio da localização nas parcelas dos cinco tratamentos. Os tratamentos consistiram de cinco preparos distintos de solo, proporcionando rugosidades diferentes, sendo que a aração foi comum a todos os tratamentos, gradagem apenas em quatro tratamentos e em três tratamentos foi utilizada a enxada rotativa com três regulagens diferentes. Para obtenção das imagens aéreas colocou-se duas câmeras digitais a bordo de um balão inflável, uma para captar imagens coloridas e a outra configurada para captar na faixa do infravermelho. Dois circuitos foram desenvolvidos para disparar as câmeras remotamente, um denominado de base terra onde se configurava o modo de disparo, manual ou

automático, e outro denominado de base remota onde as câmeras foram plugadas. O balão foi posicionado em quatro alturas, 4, 20, 50 e 100 m. As imagens obtidas foram processadas utilizando técnicas de matriz de co-ocorrência de onde foram extraídos oito descritores de textura das imagens, também avaliou-se a influência do tamanho dos blocos retirados da imagem para a classificação das classes de rugosidade nas imagens. A amostragem do solo foi feita para medida da umidade, textura e análise química para a caracterização do solo. O tratamento com apenas aração apresentou o maior índice de rugosidade, e o menor foi para o tratamento com arado, grade e enxada rotativa com tampa traseira fechada. O perfilômetro não distingue as cinco classes de rugosidade, estatisticamente. Em relação ao tamanho dos blocos da imagem, o bloco com maior dimensão, 250x250 pixel apresentou os maiores valores do índice kappa, para altura de 4 e 20 m. Na altura de 50 m o bloco 90x90 pixel teve melhor desempenho. Os sistemas de aquisição de imagens desenvolvidos são totalmente viáveis para uso em técnicas de sensoriamento remoto. Os ângulos de orientação do pixel vizinho para a montagem da matriz de co-ocorrência com melhor desempenho na classificação foram de 45° e 135°. Apenas as bandas B, R e IV B, para a altura de 20 m, tiveram valores do índice kappa igual a 1,0. Nas imagens com as câmeras a 100 m, as bandas R e G, tiveram valor do índice kappa igual a 1,0. As bandas B, IV G e IV B tenderam a apresentar maior porcentagem dos índices kappa acima de 0,90. A combinação dos descritores texturais que tendeu a ter maiores valores do índice kappa foi com a combinação de 2, 3, 4 e 5 descritores. O classificador proposto se mostrou confiável para o estudo da rugosidade superficial do solo. O classificador discriminou as cinco classes de rugosidade superficial do solo.

ABSTRACT

REIS, Leonardo Rubim, D.Sc., Universidade Federal de Viçosa, February, 2009. **Evaluation of soil surface roughness using remote sensing techniques and analysis of image.** Adviser: Luciano Baião Vieira. Co-advisers: Nerilson Terra Santos and Carlos Ernesto Gonçalves Reynaud Schaefer.

To study the top-soil rugosity using the remote sense techniques, we used one area of 1.200 m², divided on three blocks with five treatments each one, where the dimensions of the parcels were from 20 m of length by 3 m of wideness and 1 m between each parcel, and each block had an area of 20 x 18 m. In every block it was made an assortment of the localization of the parcels of the five treatments. The treatments consisted in five distinct ways to prepare the soil, where the plowing was made in all treatments. The harrow was used only in four treatments and in three treatments we used the rotavator with different regulations, providing different rugosities. To obtain the aerial images, we put two digital cameras in a balloon. One camera had colored images and the other was prepared to collect the infrared images. It was developed two circuits to shoot the cameras remotely. One circuit, named of base earth, where it was configured the way to shoot: manual or automatic. The other circuit was named remote base, where the cameras were plugged. We evaluated for heights: 4, 20, 50 e 100 m. The images obtained were processed with the co-occurrence

matrix techniques where there were extracted eight texture descriptors of the images. We still evaluated the influence of the size of the blocks, removed from the image to classify the rugosity classes in the images. It was made a soil sampling to measure the moisture, texture and chemical analysis as a characterization of the soil. The treatment only with the plowing presented a higher rugosity index and the smaller was for the treatment with the plow, harrow and rotavator with the cover closed. The perfilometer doesn't distinguish the five rugosity classes, statistically. In relation to the size of the blocks of the image, the block with the bigger dimension, 250x250 pixels presented the higher values of the kappa index for the heights of 4 and 20 m. For the height of 50 m, the block 90 x 90 obtained the best result. The systems developed to obtain the images are completely practicable to use with the remote sense techniques, with the advantage to be cheaper. The angle orientation of the pixel to produce the co-occurrence matrix with a better performance in the classification was for 45° e 135°. Only the bands B, R and IV B, for the height of 20 m, had the kappa index values the same as 1,0. The bands B, IV G and IV B had the tendency to present a higher % of the kappa index up than 0,90. The combination of the texture descriptors had the tendency to have higher values of the kappa index with the combination of 2, 3, 4 and 5 descriptors. The proposed classifier was considered reliable to study the top-soil rugosity. The classified distinguished the five classes of the top-soil rugosity.

1. INTRODUÇÃO

Entre os vários fatores que influenciam na produtividade e no custo de produção agrícola, o preparo do solo tem uma importância significativa. O objetivo básico do preparo é alterar a estrutura do solo de modo a fornecer condições físicas, químicas e biológicas à germinação, crescimento e produção das plantas. Apesar de propiciar condições favoráveis ao crescimento e produção das plantas, o preparo intensivo do solo tem contribuído para a formação de camadas compactadas e deterioração de sua estrutura, sendo a erosão pela ação da chuva uma das mais graves conseqüências.

O método mais freqüentemente utilizado para avaliar o acúmulo de água sobre a superfície do solo é a caracterização indireta, a partir de parâmetros como a cobertura vegetal e a rugosidade superficial (ONSTAD, 1984; HUANG, 1998). Portanto, o conhecimento da rugosidade superficial permite avaliar indiretamente a retenção de água nas microdepressões do solo, bem como caracterizar as alterações ocorridas no micro-relevo, em função do impacto das gotas de chuva.

A rugosidade da superfície do solo é representada pela ondulação do terreno, mais precisamente pelas variações de altura das microelevações e de profundidade das microdepressões superficiais, bem como pela sua distribuição espacial (KUIPERS, 1957; ALLMARAS et al., 1966).

O aumento da rugosidade superficial do solo é responsável pelo aumento da armazenagem de água na superfície (PAZ GONZÁLEZ; TABOADA

CASTRO, 1996), da infiltração de água no solo e da retenção de sedimentos e, por isso, pela redução da erosão hídrica.

O método mais utilizado para medição da rugosidade em campo é o uso do perfilômetro de haste. Seu mecanismo de leitura, assim como sua manipulação, modifica a superfície lida devido ao contato mecânico existente entre as agulhas e a superfície do solo. Portanto, esse instrumento não permite que duas ou mais leituras sejam realizadas no mesmo local, mas somente próximas umas das outras.

As técnicas que podem auxiliar neste aspecto são o sensoriamento remoto e o processamento de imagem. O sensoriamento remoto pode ser definido como uma técnica de obter informações sobre objetos ou fenômenos na superfície terrestre através de sensores, colocados em plataformas aéreas, orbitais e terrestres, sem que haja contato físico entre o alvo e os sensores.

Demattê et al. (2005) estudaram características físicas e químicas do solo através de imagens de satélites e concluíram que é possível caracterizar e discriminar espectralmente certas características, demonstrando que os atributos principais atuantes na reflectância orbital são a granulometria e o teor de matéria orgânica. Concluíram ainda que uma mesma classe de solo, porém com classe textural diferente, pode ser discriminada por sensoriamento remoto.

Alguns fatores que influenciam a reflectância do solo são umidade, textura (proporção de areia, silte e argilas), rugosidade da superfície, presença de óxido de ferro e conteúdo de matéria orgânica. Esses fatores estão correlacionados, visto que solos arenosos geralmente são bem drenados produzindo alta reflectância. Contudo para dois solos secos, aquele de textura mais arenosa apresenta menores valores de reflectância do que o solo de textura mais argilosa. A presença de matéria orgânica, óxido de ferro e o aumento da rugosidade também reduzem a reflectância (MACIEL, 2005).

Para Santos et al. (2005), os produtos de sensoriamento remoto possuem uma inestimável utilidade no mapeamento de feições ou de propriedades específicas dos solos, principalmente agrícola, que utilizam basicamente as informações superficiais. Para a identificação e análise destas feições, podem-se utilizar 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.

Segundo os mesmos autores, o objetivo da maioria das aplicações em sensoriamento remoto é para discriminar e pré-determinar através de mapas as informações das classes a serem encontradas no campo, comumente com a ajuda de agrupamentos estatísticos ou métodos discriminantes.

Para solos, a grande variabilidade espacial de sua constituição tem limitado os processos de avaliação "in situ". Acredita-se que, por análise de imagem, pode-se chegar a uma opção viável para avaliar as condições do solo à distância reduzindo os custos e o tempo.

Diante do exposto acima, este trabalho tem como objetivo geral avaliar a rugosidade superficial do solo, utilizando técnicas de sensoriamento remoto e de processamento de imagem, como a análise de textura baseada na matriz de co-ocorrência, para aplicação em pequenas e médias propriedades agrícolas.

Como o estudo proposto é inédito, faz-se necessário selecionar as melhores características da imagem para discriminar a rugosidade superficial do solo. Assim os objetivos específicos deste trabalho são:

- avaliar o sistema de aquisição de imagem desenvolvido;
- identificar a melhor resolução espacial, variando a altura de aquisição da imagem, para se trabalhar com o sistema de sensoriamento remoto proposto;
- identificar a melhor dimensão de blocos da imagem nas bandas (R, G, B) nos comprimentos de onda visível e infravermelho próximo;
- identificar dentre os descritores texturais utilizados, os que correlacionem com o índice de rugosidade;
- testar o classificador bayesiano estatístico para estudo da rugosidade superficial do solo.

2. REVISÃO DE LITERATURA

2.1. Rugosidade superficial do solo

As condições físicas da superfície do solo desempenham papel primordial no processo da erosão, quer dificultando ou facilitando, seja ela causada pelo impacto das gotas de água da chuva, pela enxurrada associada, ou pelo vento. As mais importantes são: a cobertura por resíduos culturais; a rugosidade superficial induzida pelos métodos de preparo; a presença de selamento ou crostas e a resistência do solo ao cisalhamento.

No entanto, na ausência de cobertura do solo por resíduos culturais e dos benefícios dela decorrentes, a rugosidade superficial do solo assume importância redobrada na redução da erosão hídrica, que ocasiona perda de nutrientes, além de contaminar os mananciais e outras áreas fora do local de origem, diminuindo a produtividade agrícola pelo empobrecimento do solo.

As perdas de nutrientes por erosão hídrica são influenciadas pela sua concentração na água e nos sedimentos e pela perda total de água e de sedimentos por erosão, a concentração de nutrientes na água e nos sedimentos, varia com sua concentração no solo, a qual é influenciada pelas adubações e pela cobertura e manejo do solo (BERTOL et al., 2003; GUADAGNIN et al., 2003).

A rugosidade na superfície em um solo preparado influencia a quantidade de água que pode ficar retida nas depressões durante e após uma

chuva. As pequenas depressões retêm por mais tempo a água empoçada na superfície, retardando o início do escoamento e reduzindo a velocidade e a energia cinética do escoamento, diminuindo, assim, o arraste e a dispersão de agregados pela enxurrada, iniciando a erosão (MELLO, 2004).

Em adição, a rugosidade superficial do solo causa aprisionamento dos sedimentos da erosão, promovendo sua deposição na área de ocorrência do fenômeno, reduzindo, assim, mais ainda as perdas de solo da lavoura (BURWELL; LARSON, 1969; COGO, 1981; COGO et al., 1983; LEVIEN et al., 1990).

O decaimento da rugosidade é influenciado pelo volume e intensidade de chuvas e de enxurrada, e pelo tipo e manejo de solo (PAZ GONZÁLEZ; TABOADA CASTRO, 1996; ELTZ; NORTON, 1997; BERTOL et al., 2006; CASTRO et al., 2006).

Segundo alguns autores a rugosidade é afetada pela densidade e porosidade do solo (LEHRSCHE et al., 1987), e pela estabilidade de agregados em água (BERTOL et al., 2006), as quais dependem do manejo do solo e, por isso, influenciam a qualidade da estrutura e regulam a velocidade e o grau de sua degradação.

Os preparos de solos conservacionistas caracterizam-se, em geral, pela presença de maior rugosidade (exceto a semeadura direta) e cobertura superficial do que os convencionais. Assim, as perdas de água e sedimentos são reduzidas nos sistemas conservacionistas, o que diminui as perdas totais de nutrientes por erosão nesses sistemas de manejo (BERTOL, 1994).

As operações de preparo do solo, como a escarificação, criam um microrrelevo na superfície do solo, sendo o índice de rugosidade superficial do mesmo o critério mais utilizado para a sua determinação. Essas alterações afetam o escoamento superficial e o armazenamento temporal de água (VÁZQUEZ ; DE MARIA, 2003).

O preparo convencional do solo, quando recente, induz maior rugosidade superficial e, com isto, maior capacidade de retenção e de infiltração de água da chuva na sua superfície, resultando em considerável retardamento da enxurrada e em relativamente baixo escoamento superficial, independentemente do cultivo e da incorporação ou remoção dos resíduos culturais (VOLK et al., 2004).

Estudos realizados por Boller et al. (1997), Dallmeyer (1994) e Secco e Reinert (1997) demonstraram o efeito de implementos de hastes sobre o aumento da rugosidade superficial. Destacaram que esse tipo de preparo aumentou de duas a quatro vezes a rugosidade superficial do solo em relação a outros manejos e que, mesmo com o passar do tempo, essa rugosidade manteve-se mais elevada.

O microrrelevo superficial é dependente: do tipo e da intensidade de preparo, e do teor de água do solo antecedente ao preparo; da quantidade, tipo e manejo de resíduo vegetal existente no solo; e do tipo de solo (KAMPHORST et al., 2000; BERTOL et al., 2006; CASTRO et al., 2006).

Castro et al. (2006) constataram que, dentre os preparos de solo conservacionista, o cultivo mínimo normalmente ocasiona elevada rugosidade superficial, em consequência dos equipamentos utilizados e da menor intensidade de mobilização do solo e dos resíduos vegetais que são semi-incorporados ao solo. Conclui que o cultivo mínimo apresenta maior rugosidade superficial do que o preparo convencional e este maior do que a semeadura direta e do que o solo sem cultivo.

Silva et al. (2005) avaliaram os efeitos do arado de aivecas e da enxada rotativa sobre a camada arável do solo, concluíram que o uso do arado de aivecas proporciona maior modificação da rugosidade do solo em relação ao uso da enxada rotativa.

Gamero e Benez (1990), Santos (1993), Coan (1995) e Oliveira (1997) sugerem que a avaliação da rugosidade superficial de um solo pode ser feita por meio da utilização do índice de rugosidade proposto por Allmaras et al. (1966). A rugosidade do solo deve ser medida, também, após o preparo. Desta maneira, pode-se determinar o índice de rugosidade da superfície mobilizada, que expressa, em termos percentuais, a mudança entre a rugosidade inicial e rugosidade final, após o preparo do solo.

O método utilizado atualmente para medir a rugosidade é por meio do perfilômetro de hastes, com número de hastes variáveis, normalmente este número fica em torno de 20 hastes, com altura e distância fixa entre cada haste, normalmente de 5,0 cm, perfazendo uma leitura de 1,0 m de largura. Este é um método no qual não é possível medir a rugosidade novamente no

mesmo lugar, ou seja, é destrutível, pois há contato das hastes com a superfície do solo.

Bertolani et al. (2000) estudaram a variabilidade espacial da rugosidade superficial do solo a partir de uma grade de dados pontuais medidos com instrumentos de diferentes graus de precisão, em laboratório utilizou um rugosímetro a laser e em campo foi utilizado um rugosímetro de agulhas, e as leituras foram realizadas em quatro datas distintas.

Os autores verificaram uma alta dependência espacial para a rugosidade superficial, com os dados obtidos em ambos os métodos e em todos os tratamentos. O rugosímetro a laser foi o mais indicado para descrever o efeito acumulativo da chuva, nas microvariações superficiais, por permitir repetidas leituras em um mesmo local de amostragem.

2.2. Sensoriamento remoto

O início do sensoriamento remoto está ligado ao desenvolvimento da fotografia e à pesquisa espacial. Os primeiros produtos de sensoriamento foram as fotografias aéreas.

Relatos datam que a primeira fotografia foi em 1839 por Daguerre e Niepce, e o seu uso foi recomendado em 1840 para levantamentos topográficos. Em 1858, o Corpo de Engenharia da França utilizou fotografias tomadas a partir de balões para o mapeamento topográfico de amplas áreas do território francês.

Outro relato do uso de sensoriamento remoto foi para uso militar, com o desenvolvimento de uma câmera fotográfica leve, com disparador automático e ajustável. Estas câmeras carregadas com pequenos rolos de filmes eram fixadas ao peito de pombos-correios, que eram levados para locais estrategicamente escolhidos de modo que, ao se dirigirem para o local de suas origens, sobrevoavam posições inimigas. Durante o percurso, as câmeras, previamente ajustadas, tomavam fotos da área ocupada pelo inimigo. Vários pombos eram abatidos a tiros pelo inimigo, mas boa parte conseguia chegar ao destino, e as fotos obtidas era material informativo valioso para o reconhecimento da posição e infra-estrutura das forças militares inimigas (FIGUEIREDO, 2005).

Com a invenção do avião e também, o desenvolvimento das câmeras fotográficas, houve um grande avanço nas aplicações de fotografias para o levantamento de recursos naturais, pois permitia a obtenção de imagens sob condições controladas e com cobertura de áreas relativamente amplas, as primeiras fotografias aéreas datam de 1909, sobre o território italiano (NOVO; PONZONI, 2001).

O termo sensoriamento remoto apareceu em meados da década de 60, significando a aquisição de informações sem contato físico com o alvo.

Na década seguinte foi lançado o primeiro satélite experimental de levantamento de recursos terrestres (Earth Resources Technology Satellite), que mais tarde teve o seu nome modificado para Landsat, sendo o sistema de sensoriamento de maior duração existente. Atualmente existe um grande número de satélites de sensoriamento remoto em operação. Na Tabela 1 encontram-se algumas dessas missões (NOVO; PONZONI, 2001).

Tabela 1 – Principais missões de sensoriamento remoto orbital em operação

Missão	Lançamento	Pais	Situação
ARIES	2001	Austrália	Ativo
CBERS-1	1999	China/Brasil	Ativo
CBERS-2	2001	China/Brasil	Ativo
EOS-AM1 (TERRA)	1999	EUA	Ativo
EROS-A1	2000	Israel	Ativo
EROS-A2	2001	Israel	Ativo
ERS-2	1995	ESA	Ativo
ENVISAT	2001	ESA	Ativo
IKONOS-2	1999	EUA	Ativo
IRS-1B	1991	Índia	Ativo
IRS-1C	1995	Índia	Ativo
IRS-P6	2001	Índia	Ativo
KITSAT-3	1999	Coreia	Ativo
QUICKBIRD-2	2001	EUA	Ativo
RADARSAT-1	1995	Canadá	Ativo

Fonte: Novo e Ponzoni (2001).

A aquisição dos dados é definida pelo tipo de plataformas utilizadas no sensoriamento remoto. Esses níveis podem ser: orbital (representados pelas plataformas espaciais), aéreo (representados pelas aeronaves tripuladas ou não) e terrestre (representados por torres, e sistemas radiométricos de campos).

As plataformas espaciais são chamadas de satélites artificiais, que são estruturadas para suportar o funcionamento de instrumentos de diversos tipos e, por isso, são equipadas com sistemas de suprimento de energia (painéis solares que convertem a energia radiante do sol em energia elétrica e a armazenam em baterias), de controle de temperatura, de estabilização, de transmissão de dados, etc.

Existem diversas categorias de satélites, que são diferenciados quanto aos objetivos principais para os quais foram criados: militares, científicos, de comunicação, meteorológicos e os de recursos naturais e em função do tipo de órbita: satélites geoestacionários e satélites de órbita polar.

Os satélites, embora demandem grandes investimentos e muita energia nos seus lançamentos, orbitam em torno da Terra por vários anos. Durante sua operação em órbita o consumo de energia é mínimo, pois são mantidos a grandes altitudes onde não existe resistência do ar e a pequena força gravitacional terrestre é equilibrada pela força centrífuga do movimento orbital do satélite (FIGUEIREDO, 2005).

O custo para lançar os satélites no espaço, é uma das principais desvantagens do uso desta tecnologia, além do custo de aquisição das imagens, não capta informações diretas abaixo da superfície; não pode ser usado como medida de perfil vertical na terra ou no mar; há Interferências da atmosfera na imagem; aquisição de imagem só é possível na hora em que o satélite passar pela região onde esta a área de interesse; necessária correção geométrica das imagens; tempo transcorrido entre a passagem do satélite e o resultado interpretado da imagem, cerca de dois meses, presença de nuvens atrapalhando a visão na imagem.

Na Tabela 2, está o preço para um pedido mínimo de 49 km² por área que esteja no catálogo *on line* da empresa, já na Tabela 3 os preços para cenas que não estão no catálogo on-line da empresa, necessitando de programação de aquisição do IKONOS, e para imagem do satélite LandSat 5,

contida no catálogo da empresa, com todas as bandas, o preço médio fica em torno de R\$ 1.300,00, essas informações foram retiradas do site de uma empresa comercial, ENGESAT.

Tabela 2 – Preços de aquisição de imagens pelo satélite IKONOS

Tipo de imagem e situação de sua disponibilidade	Preço por km ² em R\$ colocado no Brasil
PAN, 1m de resolução P&B, imagem existente do catálogo	34,00
MS, 4 m de resolução colorido, imagem existente do catálogo	34,00
PSM, 1 m de resolução colorido, imagem existente do catálogo	38,00
PAN e MS juntos no pedido, separadamente, imagem existente do catálogo	48,00

Fonte: Engesat (2007).

Tabela 3 – Preços de imagens que não estão contidas no catálogo *on line*

Tipo de imagem e situação de sua disponibilidade	Preço por km ² em R\$ colocado no Brasil
PAN, 1m de resolução P&B, imagem mais recentes ou a programar	68,00
MS, 4 m de resolução colorido, imagem mais recentes ou a programar	68,00
PSM, 1 m de resolução colorido, imagem mais recentes ou a programar	72,00
PAN e MS juntos no pedido, separadamente, imagem mais recentes ou a programar	99,00

Fonte: Engesat (2007).

Outra plataforma bastante utilizada para aquisição de imagens em sensoriamento remoto é por meio do uso de câmeras a bordo de aviões, chamada de plataformas aéreas. Com o avanço da tecnologia das câmeras aéreas tem-se conseguido uma resolução espacial, por enquanto, maior que as imagens provenientes dos satélites, e podendo adquirir as imagens na época em que se desejar.

Para a realização da cobertura aerofotogramétrica é necessária uma autorização do Ministério da Defesa, onde devem ser informados a localização e limite da área a ser levantada. Somente depois da autorização o vôo poderá ser realizado.

Essas características tornam o custo alto de aquisição das imagens aéreas, utilizando avião tripulado, sendo viável apenas para projetos em grandes extensões de terra. Para o uso no gerenciamento de fazendas em áreas menores muitas vezes, devido ao custo torna-se inviável.

Em um estudo de imagem obtida por meio de câmeras acopladas em um avião modelo Cessna 172, Castro et al. (2004) avaliaram que o custo de obtenção das imagens foi de 200 euros/hora de vôo.

Uma alternativa, para diminuir os custos das imagens aéreas, tem sido a utilização dos veículos aéreos não tripulados, "VANT". O custo de "VANT" tem baixado devido a crescente disponibilidade de recursos computacionais de alto desempenho, dos avanços em tecnologias de transmissão de dados e de posicionamento global. Com esses recursos permitem o desenvolvimento de veículos mais confiáveis e versáteis.

Os "VANT's" podem conter todos os elementos das aeronaves em escala real como motor e dispositivos de controle, e também podem transportar câmeras de vídeos, radares, lasers, sensores meteorológicos e sensores que detectam agentes químicos ou radioativos, etc. Variam na forma em que os dados são coletados podendo ser em tempo real, através de um link de rádio, ou armazenados na própria aeronave.

Os sistemas de comunicação mais utilizados em "VANT's" são: Radio modem, que estabelece um canal de comunicação bidirecional entre dois computadores; Radio Ethernet, comunicação bidirecional permitindo a conexão de um computador a vários outros; e Link de vídeo, que é unidirecional,

transmitindo imagens adquiridas por uma câmera instalada no “VANT” para uma estação de operação (MAETA, 2001).

Podem variar quanto à estrutura, tamanho e modelo, os tipos mais comuns são aviões, helicópteros e dirigíveis. Os aviões são mais fáceis de pilotar que os helicópteros e menos sensíveis a danos causados por erros do piloto, já os dirigíveis apresentam algumas vantagens sobre o avião e o helicóptero como maior estabilidade de vôo e menor risco a danos. Por outro lado, o controle de um dirigível na presença de vento é complicado e algumas vezes impraticável (NERIS, 2001).

Outros tipos de plataformas aéreas para aquisição de imagens podem ser por meio de balão com gás hélio e pipa profissionais de grandes dimensões.

Um dos modelos de balão encontrados para uso em sensoriamento remoto é uma combinação de balão com pipa, sendo que usa-se o empuxo do gás hélio para o vôo e a sustentação pelas “asas” imitando uma pipa, buscando um vôo eficiente e estável ao balão. A altitude e a direção do balão são controladas através de uma corda (Figura 1). O sistema de aquisição de imagem é acoplado na base do balão.



Figura 1 – Balão modelo “SKYHOOK HELIKITES”.

Podem ser de diversos volumes dependendo do interesse e do peso do equipamento, por exemplo, para um balão com volume de gás de 1,6 m³, o peso máximo de carga é de 2,5 kg, em condições que não há ventos fortes (24 km/h).

Silva Júnior (2006), para avaliar efeitos de doses de nitrogênio em pastagem, utilizou um balão tipo “blimp”, de forma esférica, com 4 m de diâmetro, volume de gás hélio de 33 m³, que apresentava um empuxo suficiente para levantar o equipamento de aquisição de imagem utilizado que pesava cerca de 12 kg.

Este tipo de balão apresenta uma grande desvantagem, além da instabilidade no voo, para fazer a sustentação e o arraste do mesmo, é necessário um conjunto de três cordas, cada uma com um ajudante que direcionavam o balão.


Alguns modelos têm maior facilidade de operação por meio de consoles com controles eletrônicos, para o controle das funções das câmeras, como zoom, rotação e disparo, e controle do balão (Figura 2).



Fonte: Balloide-photo (2007).

Figura 2 – Balão e o sistema de controle.


A vantagem do uso do balão é o baixo custo, facilidade no manuseio, apenas um operador, e a possibilidade do controle da altura, sendo possível aquisição de imagens em alturas menores (Figura 3). A grande desvantagem é a instabilidade em condições de ventos fortes, fazendo com que o balão perca a estabilidade de voo.



Fonte: Balloide-photo (2007).

Figura 3 – Comparação da altura de trabalho do balão com aeromodelos.

As desvantagens do uso das pipas são a forte influência dos ventos na direção de vôo, afetando a estabilidade lateral, o efeito “ioiô”, no qual a câmera sobe e desce devido ao movimento da linha e o risco de queda caso cesse os ventos. Por outro lado o custo de aquisição e manutenção é muito baixo, viabilizando o seu uso em sensoriamento remoto (Figura 4).



Fonte: Disponível em: <<http://ube-164.pop.com.br/repositorio/16195/meusite/details.htm>>.

Figura 4 – Detalhe do pêndulo com o local da câmera.

As informações adquiridas por meio do “VANT” podem ser úteis para a agricultura, como: agricultura de precisão, zoneamento de microbacias, monitoramento do uso do solo, detecção de pragas e doenças de plantas, estudos ambientais (avaliação de impactos), levantamentos florestais, vegetação ciliar, corredores ecológicos, fenômenos naturais (secas, geadas, inundações), determinação do número de plantas por ha, distribuição de palha no solo e a identificação da cobertura do solo.

A diferença entre as imagens aéreas obtidas por satélite e por plataformas aéreas está no nível de detalhes que cada um fornece. Enquanto a imagem de satélite abrange áreas superiores a 100 x 100 km e resolução espacial de 30 m de pixel, na fotografia aérea a área pode ser regulada pela altitude da aeronave, podendo variar de alguns centímetros a alguns metros. Apesar disso existem satélites como o IKONOS cuja resolução espacial é bem maior, porém ainda com custo mais elevado. No caso dos satélites existe também a periodicidade, que, por exemplo, pode ser de até 16 dias, período que nem sempre pode coincidir com o pico do ciclo vegetativo da cultura.

Na Tabela 4, estão algumas diferenças entre as plataformas aéreas discutidas anteriormente.

2.3. Uso de câmeras digitais no sensoriamento remoto

Imagens IKONOS e QUICKBIRD podem fornecer informações detalhadas sobre os alvos na superfície da Terra, com resoluções espaciais próximas de 1 m e em períodos de tempos curtos, o que permite constante atualização. Essa alta resolução permite que sejam feitas as mais diversas análises de uma área, como por exemplo: planejamento rural, agricultura de precisão, e monitoramento agrícola. A desvantagem deve-se ao fato de que essas imagens possuem um alto custo e necessitam de modernas técnicas e equipamentos para o seu processamento (SILVA, 2002).

Tabela 4 – Comparação entre os diferentes tipos de plataformas aéreas

Aspectos	Tipos de plataformas											
	Avião		Helicóptero		Dirigível		Balão		Pipa			
	Vantagem	Desvantagem	Vantagem	Desvantagem	Vantagem	Desvantagem	Vantagem	Desvantagem	Vantagem	Desvantagem		
Pouso e decolagem		Necessita de área para pouso e decolagem	Em qualquer lugar pouso e decola		Necessita de área para pouso	Decola em qualquer lugar		Decola e pouso em qualquer lugar	Restrição a lugares com muitas árvores e rede elétrica	Em qualquer lugar	Restrição a lugares com muitas árvores e rede elétrica	
Trajectoria	Possui capacidade de realizar a rota		Possui capacidade de realizar a rota		Depende das condições do vento para seguir a rota				Depende das condições do vento para seguir a rota		Depende das condições do vento para seguir a rota	
Condições climáticas	Possui certo grau de tolerância maior para voar com ventos		Possui certo grau de tolerância maior para voar com ventos		Possui baixa tolerância em condições de vento				Possui baixa tolerância em condições de vento	Necessita de vento para voar		
Custos	Custo de construção e manutenção relativamente baixo			Alto custo de aquisição e manutenção				Baixo custo de manutenção e aquisição relativamente baixo		Custo de aquisição baixo e manutenção baixíssima		
Transporte	Recurso de desmontar para transporte		Fácil transporte		Difícil transporte devido ao grande volume de reservatório de gás				Transporte dificultado, dependente do volume de gás	Fácil transporte		
Transporte de carga	Suporta carga considerável		Suporta carga considerável		Não suporta carga pesada				Não suporta carga pesada			Não suporta carga pesada

Como alternativa tem crescido o uso de câmeras digitais profissionais de pequeno e médio formato. Essas câmeras são pequenas, leves, de fácil manejo, de custo reduzido e, como são embarcadas em plataformas aéreas, possibilitam a aquisição de imagens com alta resolução espacial. Apesar destas vantagens, nos levantamentos convencionais, normalmente, não é adquirida a banda do infravermelho próximo. As câmeras digitais com essa característica não são comuns e seu custo é elevado, comparado com câmeras digitais comuns. Uma alternativa é adaptar câmeras digitais, eliminando o filtro interno infravermelho e introduzindo, externamente, um filtro bloqueador do visível (TOMMASELLI et al., 2005 apud SARTORI et al., 2007).

Para a discriminação e estudo de determinados alvos utilizando-se técnicas de Sensoriamento Remoto é imprescindível à utilização da banda do infravermelho próximo. Segundo Sartori et al. (2007), a banda do infravermelho próximo é responsável pelo registro da energia refletida devido a porção da biomassa da vegetação presente na cena, é útil para a identificação da cultura e realça o contraste entre cultura/solo e solo/água.

Imagens construídas com a banda infravermelha podem ter uma quantidade muito maior de informações temáticas que as convencionais (de cores naturais); entretanto, é importante ressaltar que o significado dessas cores e suas variações, devem ser analisados com base no conhecimento das assinaturas espectrais dos objetos, para extrair informações corretas sobre as suas propriedades (STEFFEN, 2006).

Segundo Ge et al. (2006), quase 90% dos estudos em sensoriamento remoto estão no comprimento de onda do visível ao infravermelho próximo do espectro eletromagnético, e que a maioria das assinaturas espectrais dos componentes do solo acontecem no infravermelho médio, isto faz com que as regiões do visível e do infravermelho sejam muito informativas para diagnosticar muitos componentes dos solos.

Everitt et al. (1988) detectaram problemas com a salinidade de solos em áreas agrícolas, utilizando imagens obtidas na faixa do infravermelho.

Wells et al. (2001) estudaram a compactação de solo através de imagens digitais na faixa do infravermelho próximo em Kentucky, USA. Concluíram que através do infravermelho, nas condições do experimento, não

houve correlação entre os dados espectrais na faixa do infravermelho com a compactação do solo.

Szakács (2003), estudando seqüestro de carbono no solo em relação a produtividade de pastagens por meio de imagens na faixa do infravermelho, diferenciou os diversos tipos de uso e cobertura do solo.

Barbosa e Roanhorse (2007) utilizaram um aeromodelo com uma câmera digital acoplada, modelo Sony DSC-P200 7, com filtros visível e infravermelho, para mapear as áreas infestadas por algaroba na estação experimental de Santa Rita, pertencente à Universidade do Arizona (EUA). Por meio do índice de vegetação da diferença normalizada (NDVI), que separa a vegetação verde do solo exposto, sendo que à medida que o NDVI aumenta, diminui a área de solo exposto, mostrou-se eficaz para verificar as modificações no estado da cobertura do solo, com a combinação de imagens das bandas do vermelho e infravermelho próximo. Os resultados permitiram concluir que os dados de NDVI podem ser utilizados para mapear áreas infestadas por algaroba.

Ruy et al. (2007) estudaram o uso de câmeras digitais convencionais comparadas com câmeras utilizadas em fotografias aéreas, a câmera utilizada foi da marca Sony F-828 de 8 megapixel com filtro para coleta de imagens infravermelhas, e as câmeras digitais aéreas Hasselblad H1D de 22 megapixel. As câmeras foram colocadas em um avião, em um suporte de fixação com amortecedores para atenuação das vibrações e uma base giratória para a correção da deriva do vôo. Concluíram que, o uso de câmeras digitais convencionais em fotogrametria para aplicações de precisão, além de aplicações ambientais, é possível, sendo que as maiores limitações das câmeras é a dimensão do sensor de coleta, que resulta num aumento no numero de imagens e de pontos medidos no projeto fotográfico, e ressalta o grande potencial da câmera com aquisição de imagem no infravermelho para aplicações ambientais.

Sama e Stombaugh (2007) utilizaram duas câmeras marca Sony, modelo DSC-U30, uma com o filtro original da câmera que barra o espectro do infravermelho, e na outra retiraram o filtro, deixando a câmera sensível ao espectro no infravermelho. Esta câmera tinha sensibilidade de 400 nm até 1100 nm, faixa do espectro entre o visível e o infravermelho, por isso utilizaram um

filtro que bloqueia a faixa do espectro visível, tornando a câmera sensível apenas ao espectro do infravermelho. Estas câmeras foram colocadas em um balão de gás hélio para adquirir imagens de cultura no campo. Os autores afirmam que o sistema de baixo custo desenvolvido é uma valiosa ferramenta para investigação em campo.

Vários pesquisadores estão trabalhando com câmeras de vídeo digitais, como Araújo et al. (2004) que avaliaram imagens obtidas por meio de videografia aérea digital multiespectral, quanto ao seu potencial na determinação de zonas de manejo e na estimativa da produtividade na cultura de soja e trigo. As imagens foram adquiridas por meio de uma câmera de vídeo, Duncantech MS3100, que captura imagens simultaneamente nas bandas do visível e parte do infravermelho próximo, e concluíram que as imagens obtidas por meio de videografia aérea digital multiespectral proporcionam informações importantes ao delineamento de zonas de manejo.

Segundo Vettorazzi et al. (2000), a aquisição de imagens através de câmeras de vídeo pode ser considerada um instrumento útil àqueles envolvidos na assistência técnica a agricultores. Apresenta um grande potencial em diversas aplicações, como na detecção e no monitoramento de doenças, de deficiências nutricionais e em levantamentos do uso do solo.

Ferreira et al. (2001) estudaram o uso de imagens digitais na avaliação da taxa de crescimento e cobertura do solo, por meio de uma câmera de vídeo convencional, padrão 8 mm, modelo TRV 15, marca Sony. O crescimento das espécies foi estimado pela taxa de cobertura do solo. Constatou que a técnica de análise de imagem digital, obtidas por meio de câmeras de vídeo, mostrou-se bastante útil para o acompanhamento e avaliação das diferentes espécies de cobertura do solo, destacando que pode ser feito o registro permanente da área de interesse, favorecendo a uma comparação com dados de diferentes épocas (análise multitemporal) ou apenas viabilizando nova classificação com a mesma imagem arquivada.

Hasegawa et al. (2004) avaliaram um sistema de aquisição e processamento com dados georreferenciados para aplicações em agricultura de precisão. O sistema foi projetado para registrar cada imagem adquirida pela câmera de vídeo digital “colorido infra-vermelho” – MS3100-CIR, simultaneamente, os dados coletados com um receptor GPS. O sistema foi

montado em um monomotor Cessna PA-18. Experimentos realizados na fazenda experimental da Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), em Uberaba, mostram a eficiência do sistema na aquisição e processamento dos dados.

Everitt et al. (1995) compararam imagens multiespectral de câmera de vídeo digital com máquinas de fotografia convencional e câmeras de vídeo analógicas. As câmeras foram equipadas com filtros amarelo-verde e vermelho, faixa do visível e a terceira máquina equipada com filtro infravermelho próximo (NIR). Conclui que a imagem da câmera de vídeo digital teve melhor resolução que a imagem analógica, mas não obteve o detalhamento melhor do que o filme, no entanto as características distinguíveis do solo na imagem com filme, podem também serem delineadas na imagem da câmera de vídeo digital.

Com o objetivo de simular as bandas 3, 4 e 5 do satélite TM Landsat, que captam as faixas do espectro 760-900 nm, 630-690 nm e 1550-1750 respectivamente, Everitt et al. (1998 apud POMPERMAYER NETO, 2002), utilizaram um sistema de vídeo constituído por três câmeras: duas com CCD COHU 4800 séries aptas a captar do espectro visível e o infravermelho próximo (400-1100nm), sendo uma delas equipada com filtro para captar o vermelho visível (625-635 nm) e outra com filtro infravermelho próximo (845-857 nm): uma câmera Hamamatsu c2741-03 capaz de captar as faixas do espectro visível, infravermelho próximo e infravermelho médio (400-2200 nm), equipada com filtro infravermelho médio (1631-1676 nm). Os autores puderam distinguir diversas características ecológicas da área analisada, com uma maior resolução espectral que a do sensor orbital.

Portanto, de acordo com as revisões relatadas acima por diversos pesquisadores, os resultados obtidos com câmeras digitais e câmeras digitais de vídeo, que captam imagens na banda do infravermelho, reforçam o potencial de sua utilização nos estudos de características do uso e cobertura do solo, porém ainda é necessário pesquisas em relação às características físicas da superfície do solo com essa tecnologia.

2.4. Classificação de imagens

Apesar das técnicas de sensoriamento remoto não poderem captar as características dos perfis dos solos, muitos dos seus parâmetros podem ser detectados através dela (IRONS et al., 1989; BARRET; CURTIS, 1992 apud SANTOS et al., 2005).

Os produtos de sensoriamento remoto, inegavelmente possuem uma 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, pode-se utilizar 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).

Segundo os mesmos autores, a classificação é um método de agrupamento de objetos em classes baseado em suas similaridades com respeito a uma ou mais variáveis, sendo que a discriminação é a determinação dos objetos para uma classe pré-definida baseada nas propriedades do objeto, sendo que ambas utilizam critérios diagnósticos bem definidos, os classificadores. O objetivo da maioria das aplicações em sensoriamento remoto é para discriminar e pré-determinar através de mapas as informações das classes a serem encontradas no campo, comumente com a ajuda de agrupamentos estatísticos ou métodos discriminantes.

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; KIEFER, 1994; MATHER, 1999).

Segundo Schowengerdt (1983), 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.

Jain et al. (2000) relatam que nos últimos 50 anos de pesquisa, foram obtidos avanços que possibilitaram a evolução da pesquisa em aplicações altamente complexas, exemplo: é o reconhecimento de faces, o qual consiste

em um programa de visão computacional que requer técnicas robustas a translação, rotação, alteração na escala e a deformações do objeto.

Os autores citam ainda outras áreas onde se utiliza o reconhecimento de padrões; bioinformática, análise de seqüência do genoma; aplicações e tecnologia de microarrays; Mineração de dados (data mining), a busca por padrões significativos em espaços multidimensionais, normalmente obtidos de grandes bases de dados e data warehouses; Análise de imagens de documentos para reconhecimento de caracteres (Optical Character Recognition – OCR); Inspeção visual para automação industrial; Busca e classificação em base de dados multimídia; Reconhecimento biométrico, incluindo faces, Iris ou impressões digitais; Sensoriamento remoto por imagens multiespectrais; Reconhecimento de fala.

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 através de agrupamentos de pixels.

Existem dois métodos de classificação: a supervisionada e a não-supervisionada, no presente trabalho foi utilizada a classificação supervisionada.

A classificação não supervisionada, segundo Richards e Jia (1999), abrange algoritmos os quais nomeiam os pixels em uma imagem a classes espectrais sem que o analista tenha conhecimento prévio dos nomes dessas classes. Neste tipo de classificação, freqüentemente são utilizados métodos de agrupamento (*clustering*). Estes procedimentos utilizam determinado algoritmo, conforme alguns critérios definidos, para determinar o número e localização das classes espectrais. O analista identifica essas classes *a posteriori*, analisando as assinaturas espectrais para determinar o que cada classe é ou

representa, podendo ser necessária a verificação através de dados de referência disponíveis que poderiam incluir mapas e visitas a campo (JENSEN, 1996).

Os métodos de classificação não supervisionados utilizam técnicas de agrupamento que possibilita a determinação de estruturas naturais inerentes às imagens, através da busca de centróides de aglomerações dos dados no espaço de atributos. Este método ao contrário do supervisionado, não utiliza parâmetros espectrais de cada uma das classes contidas na cena. Os algoritmos mais empregados são o Isoseg, Isodata, o K-média (RICHARDS; JIA, 1999).

A classificação não supervisionada é a opção mais adequada quando a área investigada é desconhecida, ou quando suas características não estão bem definidas (JENSEN, 1996; LILLESAND; KIEFER, 1994).

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.

Para realizar a classificação supervisionada, é necessário três pré-requisitos; conjunto de treinamentos – é o conjunto de objetos padrões conhecidos rotulados para representar as classe; conjunto de características – conjunto de atributos que define o espaço de características e o classificador – que é o algoritmo que realiza as medidas de similaridade (GOMES, 2001) .

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 subespaços, discriminando as classes, os mais comuns são: os classificadores de Distância Euclidiana e de Mahalanobis.

Já os classificadores paramétricos discriminam as classes através 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 baseiam-se em regras de classificação matemática, regra de erro mínimo de Bayes, que são formuladas e derivadas em uma estrutura estatística.

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

em que m é o 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 à 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.

$$P(w_i/m) = P(w_i)p(m/w_i) / p(m)$$

obtendo-se:

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

em que $P(w_i)$ é a 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 .

A probabilidade do indivíduo m ser classificado na classe w_j , $P(w_j/m)$, pode ser estimada através da função de decisão do classificador que é expressa pela equação a seguir (GONZÁLEZ; WOODS, 2000):

$$dj(m) = \ln P(Wj) - \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |Cj| - \frac{1}{2} \left[(m - m_j)^T C_j^{-1} (m - m_j) \right]$$

em que C_j é a matriz de covariância da classe j ; m , 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.

Assumindo que a dimensão dos vetores de padrões n e a probabilidade de ocorrência de cada classe $P(w_j)$ são os mesmos para todas as classes, os termos $\frac{n}{2} \ln 2\pi$ e $\ln P(w_j)$, podem ser eliminados da equação que se torna:

$$d_j(m) = -\frac{1}{2} \ln |C_j| - \frac{1}{2} \left[(m - m_j)^T C_j^{-1} (m - m_j) \right]$$

Dessa maneira têm-se uma função discriminante para cada classe, e a variável desconhecida m será atribuída à classe j que apresentar maior valor da função discriminante $d_j(m)$.

2.5. Análise de textura

Uma das formas de se extrair os atributos de regiões específicas das imagens é o método da análise de textura, o qual foi utilizado neste trabalho.

A textura é uma das características mais importantes para classificação e reconhecimento, e pode ser caracterizada por variações locais dos valores de pixels que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem. Textura pode também ser definida como um arranjo repetitivo de padrões sobre uma área, com o objetivo de medir a sua aspereza, observando fatores como as dependências de níveis de cinza, auto-correlação, entre outros. Vários métodos para classificação de imagens utilizando características de textura têm sido propostos na literatura González e Woods (2000), Marceau et al. (1990), Haralick (1973), entre outros. Entretanto, não há um método genérico ou uma abordagem formal que seja válida para uma grande variedade de imagens.

Para realizar a classificação é necessário encontrar medidas e características inerentes a cada classe que possam ser usadas para diferenciar um objeto do outro, a essas características chamamos atributos (descritores) (PONTI JÚNIOR, 2004).

A extração de atributos é responsável pela mensuração dos atributos dos objetos pertencentes à imagem em estudo, que são utilizados para identificar uma classe de padrão. O principal objetivo da extração de atributos é caracterizar os objetos, através de medidas, para ser utilizados na classificação de imagens (DUDA et al., 2001). As medidas podem ser adquiridas computacionalmente através de algoritmos simples que extraem informações de tamanho, cor do objeto, ou medidas, que através de algoritmos complexos, extraem características de forma, conectividade, textura, entre outros.

De acordo com Haralick (1973), as texturas definem uniformidade, densidade, aspereza, regularidade, intensidade, entre outras características em uma imagem. O autor caracteriza textura como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas e indicaram que os conceitos de tonalidade e textura não são independentes, tal que em algumas imagens a tonalidade é dominante e, em outras, a textura é dominante.

Nascimento (2003) cita três principais abordagens usadas em classificação de imagem para a descrição de texturas, descritas a seguir:

- **Abordagem estatística:** a textura é definida por um conjunto de medidas locais extraídas do padrão. Medidas estatísticas comuns incluem entropia, correlação, contraste e variância;
- **Abordagem estrutural:** utilizam a ideia de que texturas são compostas de primitivas dispostas de forma aproximadamente regular e repetitiva, de acordo com regras bem definidas. Como exemplo, pode-se citar a descrição da textura baseada em linhas paralelas regularmente espaçadas;
- **Abordagem espectral:** baseiam-se em propriedades do espectro de Fourier, sendo principalmente utilizadas na detecção de periodicidade global em uma imagem através da identificação de picos de alta energia no espectro.

Como todo o processamento de classificação de imagem da presente pesquisa foi baseado na abordagem estatística de textura, deste ponto em diante será elucidada apenas a abordagem estatística.

A obtenção das medidas estatísticas para análise de textura é calculada a partir da matriz de co-ocorrência de níveis de cinza e essas medidas são denominadas de descritores.

2.6. Matriz de co-ocorrência

Uma imagem, com resolução N_x pixels na direção horizontal e N_y na direção vertical, e quantizada com N_c tons de cinza, pode ser representada como uma matriz “L” de dimensão $N_y \times N_x$, segundo a notação linha-coluna, e cujos elementos sejam os valores de tom de cinza dos pixels na posição correspondente. A matriz de co-ocorrência é uma matriz quadrada, de dimensão $N_c \times N_c$ cujo elemento da linha i e coluna j , denominado $p_d(i, j)$, corresponde a frequência de ocorrência de pares de pixels, com os tons de cinza i e j , separados por certa distância numa dada direção e sentido, que são determinados por um vetor d . O vetor d é definido por suas componentes dx e dy como representado na Figura 5 (GOMES, 2001).




Figura 5 – Matriz de co-ocorrência mostrando as componentes do vetor d .

Os elementos constituintes da matriz são definidos como: $p_d(i, j)$

$$p_d(i, j) = P_d(i, j) / R$$

em que $P_d(i, j)$ é a frequência não normalizada, dos números de ocorrência de pares de pixel, com os tons de cinza i e j , separados por um vetor d ; R , representa o número total de pares de pixels (i, j) .

Os descritores de textura são calculados a partir das matrizes de co-ocorrência de tons de cinza de pares de pixels separados por certa distância numa dada direção, independente do sentido. Sendo as matrizes simétricas e designadas por dois vetores opostos, d e $-d$.

Para a obtenção dos descritores são considerados apenas o posicionamento relativo entre cada pixel e seus vizinhos mais próximos, os pixels adjacentes, havendo, portanto, somente quatro valores possíveis 0° , 45° , 90° e 135° para o ângulo α , que designa a direção do vetor d , e três valores possíveis para suas componentes dx e dy : $\alpha = 0^\circ$, $d=(0,1)$; $\alpha = 45^\circ$, $d=(-1,1)$; $\alpha = 90^\circ$, $d=(0,1)$ e $\alpha = 135^\circ$, $d=(-1,-1)$. Cada um desses ângulos será computada uma matriz de co-ocorrência, que representa as transições de níveis de cinza entre pixels dispostos nessa orientação específica.

Para cada uma das combinações possíveis entre o pixel e o pixel vizinho (normalmente o pixel à direita, por default), será criado um elemento na matriz de co-ocorrência de tons de cinza, de forma que o tamanho da matriz de co-ocorrência será de $n \times n$, onde N_c é o número de tons presentes na imagem original.




Figura 6 – Ângulos da matriz de co-ocorrência.

3. 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 Teixeiras, MG, com coordenadas geográficas 20°42'41.12" latitude Sul e 42°51'20.98" longitude Oeste. O clima da região é, segundo a classificação de Köppen (1948), do tipo Cwb – clima tropical de altitude com verão chuvoso e temperaturas amenas. O tipo de solo é Latossolo Vermelho-Amarelo distrófico, bastante profundo e homogêneo.

As avaliações desse trabalho foram em parcelas, com dimensões de 20 m x 3 m, área total de 60 m², que foram 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 entre os blocos 5 m, área de cada bloco foi de 380 m² e área total do experimento 1.340 m² (Figura 7). A área útil das parcelas foi de 15 x 2 m, tanto para medir a rugosidade com o perfilômetro como por meio das imagens, para eliminar o efeito da bordadura no processamento.

O experimento foi instalado segundo o delineamento em blocos casualizados com três repetições, no qual foram avaliados cinco diferentes índices de rugosidades, obtidos com preparos diferenciados do solo (Figura 8).




Figura 7 – Foto aérea da área experimental, mostrando os números das parcelas e seus respectivos tratamentos: P (parcela) e T (tratamento).

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.



Figura 8 – Vista lateral do bloco 1 com os cinco tratamentos.

Os implementos utilizados para o preparo do solo foram: arado de aivecas reversível, grade leve do tipo X com 24 discos de dupla ação e enxada rotativa (Figura 9).




Figura 9 – Imagem dos implementos utilizados na fase inicial do experimento: (a) arado de aivecas; (b) grade; e (c) enxada rotativa, com tampa fechada.

A aração foi realizada em todas as parcelas, na gradagem foram realizadas três passadas e para a enxada rotativa duas passadas. Para se ter as diferenças de rugosidade com a enxada rotativa nos tratamentos 1, 2 e 3 foram utilizadas marchas diferentes no trator. Para o T1, foi utilizada a primeira reduzida, rotação do motor 1600 rpm e tampa traseira da enxada rotativa fechada, no T2, utilizou a segunda marcha reduzida, com 1600 rpm, e a tampa traseira da enxada aberta e no T3 com terceira marcha reduzida, também com 1600 rpm, e a tampa traseira fechada. O fato da tampa aberta ou fechada afeta na menor ou maior desestruturação do solo.

A hipótese H_0 para a fonte de variação tratamentos estabelece que as cinco formas de preparo do solo avaliadas neste experimento, apresentam em média o mesmo valor para o índice de rugosidade.

3.1. Análises laboratoriais

Foram retiradas amostras simples com um trado tipo holandês em três pontos nas parcelas, igualmente espaçadas de 5 m. As amostras simples foram misturadas e homogeneizadas, formando a amostra composta para cada parcela, na qual foram feitas as análises.

Uma vez no laboratório, as amostras de solo foram secas ao ar, destorroadas e passadas em peneiras com malha de 2 mm, obtendo a terra fina seca ao ar (TFSA), que foi submetida às análises abaixo descritas.

3.1.1. Caracterização física e agregação (via úmida)

Após as amostras serem secas ao ar, 10 g de TFSA foi dispersa com 50 ml de NaOH $0,1 \text{ mol L}^{-1}$, por 12 horas, e agitação em alta rotação, por 15 minutos. As frações areia grossa e fina foram separadas por tamização, em peneiras com malhas de 0,2 e 0,053 mm de abertura, respectivamente. A composição granulométrica foi determinada após dispersão da TFSA com NaOH 1 mol L^{-1} e agitação; a fração areia foi obtida por peneiramento úmido, a argila pelo método de Bouyoucus e o silte por diferença (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA, 1997).

3.1.2. Caracterização química

O pH em água e o pH em KCl 1 mol L^{-1} foram determinados potenciométricamente na suspensão solo-solução 1:2,5, com tempo de contato mínimo de 1 hora e agitação da suspensão antes da leitura; o cálcio e magnésio trocáveis foram extraídos com KCl 1 mol L^{-1} , na proporção 1:20, e dosados por absorção atômica; o potássio e sódio trocáveis foram extraídos com HCl $0,05 \text{ mol L}^{-1}$, na proporção 1:10, e dosados por fotometria de chama; o alumínio trocável será extraído com KCl 1 mol L^{-1} , na proporção 1:20, e

determinado por titulação com NaOH 0,025 mol L⁻¹; a acidez extraível - (H⁺ + Al³⁺) será extraída com solução de acetato de cálcio 1 N ajustada a pH 7,0, na proporção 1:15, e determinada por titulação com NaOH 0,0606 mol L⁻¹; o fósforo disponível será extraído com solução de HCl 0,05 mol L⁻¹ e H₂SO₄ 0,025 mol L⁻¹ (Mehlich-1) e determinado por colorimetria na presença de ácido ascórbico; o carbono orgânico será extraídos pelo método volumétrico com bicromato de potássio e por titulação com sulfato ferroso (EMBRAPA, 1997).

Os agregados foram separados por via úmida pelo método da Embrapa (1997).

3.2. Índice de rugosidade

A rugosidade foi determinada por um perfilômetro, que contém 20 hastes espaçadas entre si de 0,05 m montado sobre uma base previamente nivelada (Figura 10). Foram realizadas três leituras do perfilômetro em cada parcela experimental, o valor do índice de rugosidade, por parcela, foi a média das três leituras.

Para realizar as leituras do perfilômetro foi feito um quadrado com 1 x 1 m (Figura 10b), e a cada 0,10 m foi feita a leitura das alturas das hastes.

A cada 0,10 m mudava-se o perfilômetro de lugar para realizar a leitura, totalizando 10 leituras por m². Como o perfilômetro continha 20 hastes, o total de leituras por posição foi de 20, e em 1,0 m², 200 leituras. Em cada parcela foram realizadas 3 leituras, totalizando 600 medidas por bloco, perfazendo um total para os três blocos de 1.800 medidas. No processo manual teria que marcar todas estas medidas (alturas) das hastes em um papel milimetrado preso ao perfilômetro (Figura 10c).

A fim de agilizar o processo de leitura da altura das hastes, montou-se um suporte para sustentar uma câmera digital e o circuito utilizado no sistema de sensoriamento remoto para o disparo da máquina, como visto na Figura 10a.




Figura 10 – Perfilômetro de hastes e suporte com a câmera digital (a); quadro de 1 m² (b); e imagem obtida pela câmera colocada no suporte (c).

A câmera foi disparada a cada 0,10 m, capturando a imagem da altura das hastes (Figura 10c). Uma rotina no MatLab[®] (Apêndice A) foi elaborada para calcular o índice de rugosidade, a partir das alturas das hastes.

O índice de rugosidade superficial foi efetuado utilizando a equação (1), Allmaras et al. (1966).

$$IR = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}} \quad (1)$$

em que IR é o índice de rugosidade superficial (cm); Y , altura de cada haste (cm); \bar{Y} , média das alturas; e n = número de leituras.

A definição das cinco classes foi baseada nas diferenças de rugosidade provenientes de cada tratamento (preparo de solo), iniciando pelo que proporcionou o menor índice de rugosidade, como segue abaixo:

- Classe 1: Aração, gradagem e enxada rotativa sob baixa rotação;
- Classe 2: Aração, gradagem e enxada rotativa sob média rotação;
- Classe 3: Aração, gradagem e enxada rotativa sob alta rotação;
- Classe 4: Aração e gradagem;
- Classe 5: Aração.

Estas classes foram as mesmas utilizadas durante o processo de classificação das imagens digitais.

Estas mesmas classes foram denominadas segundo o valor do índice de rugosidade, assim a que apresentou o menor índice de rugosidade foi denominada de muito baixa e a com maior valor de muito alta, como abaixo:

- Classe 1: muito baixa;
- Classe 2: baixa;
- Classe 3: média;
- Classe 4: alta;
- Classe 5: muito alta.

3.3. Sistema de aquisição de imagens

As imagens multiespectrais das unidades experimentais que receberam as diferentes formas de preparo do solo foram obtidas simultaneamente a partir de um sistema de aquisição de imagens nas alturas de 4, 20, 50 e 100 m.

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

- 4 m – resolução espacial de 0,0013 m/pixel;
- 20 m – 0,0065 m/pixel;
- 50 m – 0,016 m/pixel;

- 100 m – 0,032 m/pixel.

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

As duas câmeras digitais utilizadas foram da marca Fuji, modelos Finepix Z10fd, com sensor CCD de 1/2,5 polegadas, resolução máxima de 7 megapixel, 3072 x 2304 pixel (Figura 11), uma para capturar na banda do visível e a outra no infravermelho próximo e um balão a gás. Estas câmeras capturaram duas imagens simultaneamente, da mesma cena. Em uma das câmeras foi acoplado um filtro óptico para que fosse adquirida imagem na banda do infravermelho próximo. Para isso foi necessário abrir uma das câmeras e retirar o filtro que bloqueia o comprimento de onda na faixa do infravermelho (Figura 12).



Figura 11 – Câmera utilizada para captar imagens coloridas (a); e câmera adaptada para captar imagem infravermelha com filtro marca B+W (b).

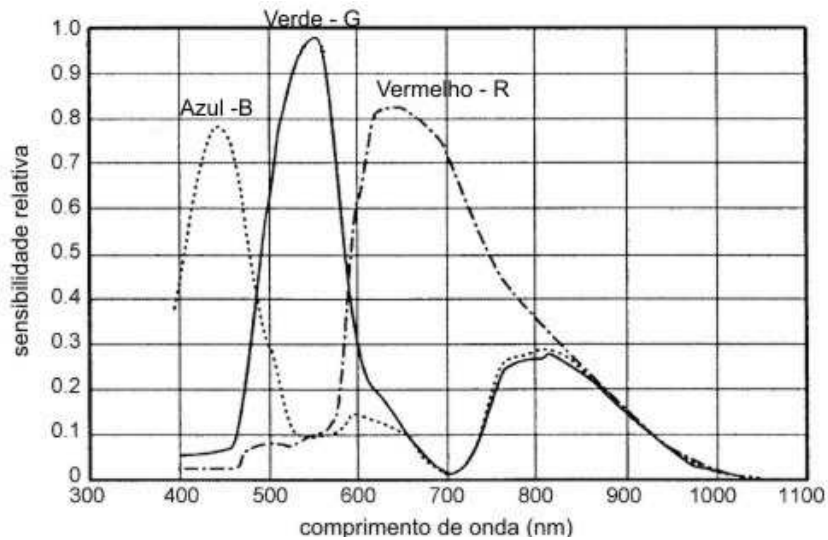


Figura 12 – Câmera aberta mostrando a retirada do filtro colorido.

O CCD (Charge Coupled Device) é um circuito integrado de silício, capaz de transformar energia luminosa em energia elétrica, composto por minúsculos diodos sensíveis a luz, que convertem fótons (luz) em elétrons (cargas elétricas). Esses diodos são chamados de “photosites”, que respondem apenas a luz e não a cor. A captura de imagens coloridas é feita utilizando-se uma matriz de filtros RGB, colocada na frente do CCD (JENSEN et al., 2007).

Como o olho humano não é sensível ao infravermelho, são colocados filtros que bloqueiam o infravermelho, ocasionando uma imagem com cores mais próximas da realidade. Por isso foi necessária a retirada deste filtro bloqueador.


Segundo Jensen et al. (2007), a maioria dos CCD é sensível ao infravermelho próximo (Figura 13), sendo necessário, por tanto o uso de um filtro para bloquear este comprimento de onda.



Fonte: Jensen et al. (2007).

Figura 13 – Resposta espectral típica de um CCD.

O filtro infravermelho óptico utilizado foi o marca B+W modelo 093, 40.5E, que bloqueia o comprimento de onda na faixa do visível, e permite a transmissão a partir do comprimento de 800 nm até 1000 nm, bloqueia toda banda do visível e 40.5 é o diâmetro em mm do filtro (Figura 14).



Fonte: Disponível em: <<http://www.2filter.com/prices/BWfilters.html>>.

Figura 14 – Curva de resposta espectral do filtro B+W 093.

O botão mecânico de aquisição de imagem das câmeras foi alterado, para que fosse acionado de maneira eletrônica (Figura 15) para capturar imagens de 5 em 5 segundos. Após a captura, as imagens foram descarregadas no computador para o processamento.




Figura 15 – Sistema eletrônico para acionamento das câmeras: base remota (a); base terra (b); e detalhe da adaptação do botão de disparo (c).

Um segundo sistema foi desenvolvido, em que o momento do início da aquisição das imagens era definido pelo usuário e a aquisição de fotos manual ou automática poderia ser dada a qualquer momento.

O sistema controlador desenvolvido tinha a opção de disparo automática ou manual (Figura 15). Este sistema possui dois circuitos, ou bases, uma denominada de base terra (Figura 15b), que fica com o operador em terra, de onde se pode escolher as configurações, manual ou automática.

Na base terra há um display onde aparecem as opções de controle e as informações de quantas imagens já foram tiradas. O segundo circuito, denominado de base remota (Figura 15a), é responsável pela recepção do sinal e realizar os disparos na câmera. A comunicação entre as duas bases é feita por meio da radiofrequência. O fluxograma e o circuito da base terra e remota estão nos Apêndices G, H e I.

A base terra tem uma interface gráfica exibida em um display LCD 16 x 02. As opções da base terra são: CONFIGURAR ou INICIAR. Em configurar, há opção de o disparo ser automático ou manual. Se automático existe a opção de mudar o tempo de disparo das máquinas, de 1 a 250 segundos, tempo este que depende do tempo de resposta da máquina entre os disparos, o disparo que é realizado pelo sistema no intervalo de tempo predeterminado. No modo manual o disparo é feito quando necessário pelo operador.

Outra informação exibida no display é o número de fotos tiradas, que podem ser zeradas 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 a fonte de energia da base remota foi utilizada uma bateria de 9 volts e para a base terra foram utilizadas três baterias de celular.

Para a transmissão do sinal utilizou-se um transmissor ASK de 315 MHZ em um canal simplex. O canal simplex é aquele em que a direção de transmissão é inalterada. A frequência de 315 MHZ foi escolhida por ser menos utilizada, favorecendo assim a diminuição de interferências referentes a outras transmissões não desejáveis (CANZIAN, 2004).

Para aquisição das imagens aéreas, as câmeras, juntamente com a base remota, foram acopladas em um balão com gás hélio (Figura 16).




Figura 16 – Suporte das câmeras acoplado no balão e detalhe da parte inferior do suporte mostrando a lente das câmeras, colorida e infravermelho.

O balão, modelo “*Skyhook Helikite*”, é uma combinação de uma pipa (papagaio) com um balão com 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 através de uma corda (Figura 17).



Figura 17 – Balão modelo “SKYHOOK HELIKITE”.

A forma do balão é tipo oval, com 1,82 m no comprimento maior, proporcionando um volume de gás hélio de aproximadamente 1,60 m³, com capacidade de carga na vertical de 0,8 kg sem vento, 2,5 kg com ventos de até 24 km/h, altitude máxima sem carga de 762 m e com equipamento 304 m.

O peso das duas câmeras com as respectivas baterias, o circuito base remota com a fonte de alimentação, bateria de 9V, o suporte das câmeras e o filtro infravermelho ficou em torno de 320 gramas.

Este tipo de balão tem como principal vantagem a estabilidade no vôo, facilidade em controlar a direção, apenas uma corda com um controlador, diferentemente do balão utilizado por Silva Júnior (2006).

A aquisição das imagens foi realizada na mesma data em que se mediu a rugosidade do solo.

A câmera foi configurada, com a resolução máxima de 3072 x 2304 pixel, 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).

3.4. Altura do balão

As imagens foram adquiridas em quatro alturas, 4, 20, 50 e 100 m (Figuras 18 e 19). Para o controle da altura do balão no vôo de campo, foi feito na própria linha de sustentação do balão marcas de 5 em 5 metros. Em uma 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 contrária, com vento, a linha ficava curva, ocorrendo uma leitura equivocada na altura do balão. Para calcular a altura em que a imagem foi adquirida foi feita uma rotina de programação no MatLab[®] com base em distâncias conhecidas nas imagens.




Figura 18 – Foto colorida a 4 m (a1); foto infravermelha a 4 m (a2); foto colorida a 20 m (b1); e foto infravermelha a 20 m (b2).

Na altura de 4 m optou-se por utilizar a configuração de disparo manual das máquinas, por meio do sistema eletrônico (base terra (controle remoto)), pois nesta altura o balão fica com o vôo mais instável, dificultando a aquisição das imagens, nas outras alturas o sistema foi configurado para disparar automaticamente.

Para o processamento as imagens foram separadas em bandas. Na colorida, as imagens foram separadas nas bandas R, G e B, e na infravermelha, nas bandas, IV R, IV G e IV B, segundo Jensen et al. (2007).

Para o processamento foi utilizada uma imagem de cada parcela, em cada altura.




Figura 19 – Fotos a 50 m: uma colorida e duas infravermelha (c); fotos a 100 m: uma colorida e duas infravermelha (d).

3.5. Tamanho dos blocos das imagens

Para obtenção dos descritores texturais as imagens foram recortadas em blocos com dimensões de 50x50, 90x90, 150x150 e 250x250 pixels, recortados em regiões de interesse (Figura 20).




Figura 20 – Tamanho dos blocos, em pixel, utilizados para a montagem da matriz de co-ocorrência.

Estes blocos foram utilizados para montar a matriz de co-ocorrência e calcular os oito descritores texturais utilizados na classificação das cinco classes de rugosidade. Nas imagens com altura de 50 m, os tamanhos dos blocos foram de 50x50 e 90x90 pixels, e na altura de 100 m apenas 50x50 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 um programa Matlab®, por meio de uma 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 uma outra rotina executava os cortes dos blocos, ao todo foram recortados 100 blocos, que representavam as cinco classes de rugosidade, totalizando 500 blocos (Apêndice B).

De cada um desses blocos foi gerada 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 blocos de cada classe.

3.6. Estudo das características do solo utilizando processamento de imagem digital

3.6.1. Melhores parâmetros para a classificação

As escolhas das características das imagens analisadas como: tamanho de blocos, ângulo de direção da matriz de co-ocorrência, bandas das imagens coloridas e infravermelha, foram realizadas com base na comparação do índice kappa pelo teste z.

3.6.2. Cálculo dos descritores

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 (Apêndice C). Foi calculada a matriz de co-ocorrência para cada um dos blocos recortados, os cálculos dos descritores foram realizados nas orientações: 0°, 45°, 90° e 135°.

Para a utilização da matriz de co-ocorrência nos cálculos dos descritores texturais foi preciso realizar a normalização da matriz, através da equação (2).

$$p(i, j) = \left(\frac{P(i, j)}{\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} P(i, j)} \right) \quad (2)$$

em que $p(i, j)$ é a 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.

Os descritores texturais foram:

- 1) Momento angular: avalia a uniformidade textural, isto é, a repetição de pares de níveis de cinza. Quando a imagem é homogênea (apenas *pixels* com valores de níveis de cinza muito próximos estão presentes) ou quando

a textura é uniforme, poucos elementos da matriz são diferentes de zero e o momento alcança valores próximos ao máximo igual a um.

$$C_1 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} [p(i, j)]^2 \quad (3)$$

em que C_1 = momento angular.

- 2) Média: avalia a tendência central dos valores dos níveis de cinza distribuídos na imagem.

$$C_2 = \sum_{i=0}^{N_g-1} i * p_x(i) \quad (4)$$

em que C_2 é a média; i , valor observado; $p_x(i)$, probabilidade marginal da matriz de co-ocorrência (soma da linha).

- 3) Variância: identifica as variações dos tons de cinza de uma imagem. Assim, pixels da imagem com valores similares fazem com que a variância tenda a zero.

$$C_3 = \sum_{i=0}^{N_g-1} (i - C_2)^2 p_x(i) \quad (5)$$

em que C_3 é a variância.

- 4) Entropia: mede a desordem de uma imagem. Quando a imagem não apresenta textura uniforme, muitos elementos da matriz de co-ocorrência têm valores muito pequenos.

$$C_4 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \ln [p(i, j)] \quad (6)$$

em que C_4 é a entropia; \ln , logaritmo neperiano.

- 5) Correlação: é a medida das dependências lineares de tons de cinza na imagem. Valores altos de correlação (próximos a um) implicam numa afinidade linear positiva entre níveis de cinza de pares de *pixels*.

$$C_5 = \frac{\left[\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} ij p(i, j) \right] - C_2^2}{C_3} \quad (7)$$

em que C_5 é a correlação; i , número da linha; j , número da coluna.

- 6) Momento do produto: retorna um valor baixo quando os valores altos da matriz de co-ocorrência estiverem próximos da diagonal, o que acontece quando os valores dos pixels das imagens não apresentam mudança brusca de tons de níveis de cinza.

$$C_6 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - C_2)(j - C_2) p(i, j) \quad (8)$$

em que C_6 é o momento do produto.

- 7) Momento inverso da diferença: mede a homogeneidade da imagem e assume valores altos para diferenças de tons de cinza pequenas nos pares de elementos.

$$C_7 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (9)$$

em que C_7 é o momento inverso da diferença.

- 8) Medidas de correlação: não existe uma interpretação física dessa medida, é uma representação da taxa de entropia da matriz de co-ocorrência.

$$C_8 = \frac{C_2 - HXY1}{HX} \quad (10)$$

em que

$$HX = - \sum_{i=0}^{N_g-1} p_x(i) \ln[p_x(i)] \quad (11)$$

$$HXY1 = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \ln[p_x(i)p_x(j)] \quad (12)$$

em que C_8 é medidas de correlação; $p_x(j)$, probabilidade marginal da matriz de co-ocorrência (soma da coluna).

Foram avaliadas todas as 255 combinações possíveis entre os descritores possíveis na formação do vetor característica para serem submetidos a um classificador.

Todos os cálculos foram realizados segundo uma rotina elaborada em um programa específico, e os dados foram salvos em planilhas eletrônicas com dimensão de 500 linhas x 9 colunas, na primeira coluna havia os números das classes, de 1 a 5, nas outras 8 colunas os valores dos descritores, para cada classe havia um total de 100 linhas, totalizando 500 linhas (Apêndice D).

3.6.3. Classificação

Para saber qual foi a melhor combinação dos descritores texturais, de um total de 255, para a formação do vetor característica de cada classe, utilizou-se a validação cruzada e o índice kappa (Apêndice E).

O classificador utilizado no processo foi o classificador bayesiano que se baseia na teoria de decisão bayesiana sob densidade normal.

No teorema de Bayes, determina-se a probabilidade *a posteriori*, $P(W_j/x)$, a qual representa a probabilidade condicional de que dado o indivíduo x ser conhecido, o mesmo pertença à classe W_j . Para o cálculo desta probabilidade *a posteriori* leva-se em consideração a probabilidade a priori de ocorrência de cada classe, $P(W_j)$ é a probabilidade condicional dada as características x dentro da classe W_j , $P(x/W_j)$. O indivíduo é classificado na classe que apresentar maior valor de $P(W_j/x)$.

A probabilidade do indivíduo x ser classificado na classe W_j , $P(W_j/x)$, pode ser estimada através da função de decisão do classificador que é expressa pela equação a seguir (GONZÁLEZ; WOODS, 2000):

$$dj(x) = \ln P(W_j) - \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (13)$$

em que C_j é a 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.

Assumindo que a dimensão dos vetores de padrões (n) e a probabilidade de ocorrência de cada classe $P(W_j)$ são os mesmos para todas

as classes, os termos $\frac{n}{2} \ln 2\pi$ e $\ln P(W_j)$, podem ser eliminados da equação que se torna:

$$dj(x) = -\frac{1}{2} \ln |C_j| - \frac{1}{2} \left[(x - m_j)^T C_j^{-1} (x - m_j) \right] \quad (15)$$

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 $dj(x)$, atribuindo-se o vetor característica a classe que apresentou maior valor da função.

Ao final da classificação foram geradas planilhas eletrônicas, com as informações: descritores utilizados na formação do vetor característica; variância do índice kappa; valor do índice kappa; matriz de classificação, para cada uma das 255 combinações dos descritores. Um exemplo deste tipo de planilha é apresentado no Apêndice F.

3.6.4. Avaliação dos classificadores

A avaliação do desempenho dos classificadores é um passo importante no sistema de classificação. Através de métodos de medição do erro obtêm-se números que indicam quais foram as performances obtidas pelo classificador utilizado.

Na validação cruzada deixando um de fora, segundo Johnson et al. (1998), ao invés de utilizar uma parte dos dados para treinamento e outra para teste, são utilizados todas as n amostras de um conjunto de dados para treinamento. Para estimar o erro são realizados n experimentos. Em cada um deles, uma amostra do conjunto de dados é retirada e o classificador é treinado utilizando as $n-1$ amostras restantes. A amostra que foi retida é então testada. Este procedimento é repetido deixando de fora uma amostra diferente a cada iteração, até que se tenham n diferentes classificações cada qual usando $n-1$ amostras.

A estimativa de erro da classificação final é dada por:

$$E = \frac{1}{n} \sum_{i=1}^n e(i) \quad (16)$$

em que E é a estimativa de erro; n , número de amostras; $e(i)$, erro em cada iteração, 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 e Ramm (1987), o cálculo do índice kappa será efetuado por meio da equação (17).

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (17)$$

em que \hat{K} é a estimativa do índice 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.

O kappa é igual a zero quando o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de kappa ocorrem quando o acerto é maior que por acaso e negativos quando o acerto é pior do que uma classificação ao acaso.

Como referência para avaliação dos valores kappa utilizou-se a classificação segundo Landis e Koch (1977 apud HORTA, 2006).

A Tabela 5 serviu de referência para comparar os índices kappas, escolhidos pelo teste z em cada classificação, isto é, para cada situação em relação à altura, tamanho dos blocos, direção do pixel vizinho e a interação dos três fatores altura x tamanho dos blocos e direção do pixel vizinho.

Tabela 5 – Valores do índice kappa

Valor	Índice 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

Após a escolha dos maiores valores dos índices kappa foi utilizado o teste estatístico (Z) para a comparação do desempenho dos classificadores gerados com diferentes combinações dos descritores texturais.

Para testar a diferença entre os índices kappa calculados, ao nível de significância de 5%, foi utilizado o teste Z (CONGALTON; MEAD, 1983) de acordo com a equação (18).

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (18)$$

em que Z é o valor de Z calculado; \hat{K}_1 , índice kappa do classificador 1; \hat{K}_2 , índice kappa do classificador 2; $\text{var}(\hat{K}_1)$, variância do índice kappa do classificador 1; $\text{var}(\hat{K}_2)$, variância do índice kappa do classificador 2.

Para determinar a variância de grandes amostras do índice kappa será usada a equação (19) (BISHOP et al., 1975 apud HUDSON; RAMM, 1987):

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (19)$$

em que $\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii}$; $\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i}$; $\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i\oplus} + x_{\oplus i})$; e

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

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

O classificador gerado serviu de base para determinação dos níveis de rugosidade superficial do solo e foram comparados com os resultados determinados em campo para essa característica.

3.7. Correlação do índice de rugosidade com descritores texturais

Foi realizada uma análise de correlação dos oitos descritores texturais utilizados no processo de classificação das imagens digitais, com os índices de rugosidades, determinados pelo perfilômetro em campo para as cinco classes.

Após o processo de escolha das melhores características das imagens processadas, como a dimensão dos blocos das imagens, o ângulo da matriz de co-ocorrência, as bandas das imagens coloridas e infravermelhas e a(s) altura(s) da câmera, utilizou-se os valores dos descritores texturais calculados com essas características.

Para efetuar a análise de correlação foram utilizados os valores médios dos índices de rugosidade em cada classe e a médias dos valores dos descritores texturais.

4. RESULTADOS E DISCUSSÃO

4.1. Análise de solo

Na Tabela 6 estão apresentados os resultados da análise de solo com os dados de textura e umidade, realizada em cada parcela dentro dos blocos.

De acordo com a Embrapa (1979), analisando os valores de argila, percebe-se que o solo da área experimental é de textura argilosa com alguma variação entre os blocos.

Em relação à umidade (Tabela 6), o solo se apresentava próximo ao ponto de murcha, isto ocorreu devido ao tempo seco, a falta de chuva durante o período de coleta das amostras, mas houve diferenças bem marcantes entre os blocos.

Os solos são todos ácidos, e necessitam de calagem corretiva, apesar do Al trocável não ser elevado. Os teores de nutrientes variaram pouco entre os tratamentos.

Comparando os dados da Tabela 7 com Alvarez et al. (1999), os níveis de Ca, Mg e Soma de Bases (SB), estão com valores dentro da faixa de baixo a médio, com Al trocável baixo. Em relação a H+Al, t e T os valores estão dentro da faixa média.

Tabela 6 – Análise de textura das parcelas experimentais

Parcelas	Areia grossa	Areia fina	Silte	Argila	Classe textural	Umidade (%)	
	dag kg ⁻¹						
Bloco 1	1	22	12	19	47	Argila	18,03
	2	21	14	18	47	Argila	13,98
	3	20	15	18	47	Argila	12,99
	4	17	14	19	50	Argila	15,82
	5	20	15	17	48	Argila	15,46
Bloco 2	1	14	12	21	53	Argila	15,05
	2	11	12	22	55	Argila	17,85
	3	12	11	24	53	Argila	22,02
	4	12	11	23	54	Argila	10,64
	5	13	12	22	53	Argila	16,13
Bloco 3	1	26	13	22	39	Franco-argilosa	14,49
	2	19	12	23	46	Argila	12,17
	3	21	13	21	45	Argila	10,63
	4	21	14	20	45	Argila	10,05
	5	22	13	21	44	Argila	8,99

Os menores valores de P disponível foram encontrados nas parcelas onde o tratamento realizado foi apenas aração. Para fins agrícolas os valores de P estão na faixa de muito baixo a baixo. Em relação ao K, os valores estão na faixa de classificação média, para um solo com porcentagem de argila em torno de 50% (ALVAREZ et al., 1999).

Silveira et al. (2000) avaliaram as características químicas de um Latossolo Vermelho-Escuro distrófico, textura argilosa, após cinco anos de uso com utilização de três sistemas de preparo para o plantio, com arado de aiveca, grade aradora e plantio direto, concluiu que os valores de pH, Ca, Mg, P e K variaram conforme o método de preparo, no sistema que usou apenas o arado os valores foram menores do que nos outros dois sistemas.

Tabela 7 – Análise química das parcelas experimentais

Blocos	Parcelas	pH	mg/dm ³			cmolc/dm ³			%			M.O dag Kg ⁻¹	
			P	K	Ca	Mg	Al	H+Al	S.B	t	T		V
1	1	5,11	4,70	62,00	2,32	0,56	0,00	4,80	3,04	7,84	38,80	0,00	2,09
	2	4,87	5,00	68,00	1,99	0,58	0,19	4,10	2,74	6,84	40,10	6,50	2,35
	3	4,84	5,00	28,00	1,75	0,43	0,39	4,60	2,25	6,85	32,80	14,80	2,09
	4	4,78	3,08	44,00	1,52	0,40	0,29	4,50	2,03	6,53	31,10	12,50	1,70
	5	4,74	2,70	41,00	1,46	0,42	0,39	4,90	1,98	6,88	28,80	16,50	2,09
2	1	4,92	2,00	54,00	1,73	0,52	0,10	4,10	2,39	6,49	36,80	4,00	2,22
	2	4,97	1,40	25,00	1,64	0,47	0,19	3,80	2,17	5,97	36,30	8,10	1,96
	3	4,93	4,20	46,00	1,53	0,52	0,19	4,10	2,17	6,27	34,60	8,10	2,09
	4	4,76	4,20	49,00	1,65	0,48	0,29	4,60	2,26	6,86	32,90	11,40	2,35
	5	4,65	6,60	51,00	1,62	0,44	0,39	5,10	2,19	7,29	30,00	15,10	2,35
3	1	5,35	1,10	19,00	1,39	0,44	0,00	2,50	1,88	4,38	42,90	0,00	1,17
	2	4,79	3,20	36,00	1,34	0,38	0,19	4,00	1,81	5,81	31,20	9,50	1,96
	3	4,80	4,30	86,00	1,34	0,44	0,19	3,80	2,00	5,80	34,50	8,70	2,22
	4	4,46	3,80	44,00	0,99	0,28	0,67	4,50	1,38	5,88	23,50	32,70	2,09
	5	4,63	5,00	26,00	1,05	0,29	0,48	4,00	1,41	5,41	26,10	25,40	1,70

P – Fósforo; K – Potássio; Ca – Cálcio; Mg – Magnésio; Al – Alumínio; H+Al – Acidez potencial; S.B – Soma de Bases; t – Capacidade de troca catiônica efetiva; T – Capacidade de troca catiônica a pH 7,0; V – Índice de saturação de bases; m – Índice de saturação de alumínio; M.O – Matéria orgânica.

4.2. Índice de rugosidade

Os resultados da análise de variância do teste F para os índices de rugosidade são apresentados na Tabela 8.

Tabela 8 – ANOVA

Fonte de variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F _{calculado}	F _{tabelado} 5 %
Blocos	2	0,17			
Formas de preparo	4	4,48	1,12	11,62	6,94
Resíduo	8	0,77	0,097		
Total	14	5,42			

De acordo com o teste F existe pelo menos uma diferença significativa entre as cinco formas de preparo com relação ao valor médio do índice de rugosidade. Para determinar quais diferenças entre formas de preparo são significativas, foi realizado o teste de Tukey, os dados são apresentados na Tabela 9.

Com a análise dos resultados da Tabela 9, verifica-se que não foi possível discriminar completamente entre si, as 5 formas de preparo, ao usar o índice de rugosidade superficial obtido a partir do perfilômetro. Contudo, este índice permitiu discriminar as formas de preparo em que o solo foi preparado usando apenas a aração daquelas que o solo foi preparado usando enxada rotativa. Os resultados da aplicação do teste de Tukey mostram que a rugosidade proporcionada pelo uso da gradagem é um valor intermediário entre o obtido ao usar apenas aração e usar também a enxada rotativa, conforme seria esperado.

Tabela 9 – Análise dos índices de rugosidade pelo teste Tukey

Formas de preparo	Blocos			Média
	1	2	3	
1	0,69	0,74	0,81	0,75 b
2	0,79	0,80	0,97	0,85 b
3	0,67	0,71	0,85	0,74 b
4	1,37	1,00	1,69	1,35 ab
5	1,62	2,77	2,12	2,10 a

As médias seguidas por uma mesma letra não diferem entre si pelo teste Tukey a 5% de probabilidade. 1 – Aração, gradagem e enxada rotativa sob baixa rotação; 2 – Aração, gradagem e enxada rotativa sob média rotação; 3 – Aração, gradagem e enxada rotativa sob alta rotação; 4 – Aração e gradagem; 5 – Aração.

Carvalho Filho (2004) avaliou cinco sistemas de preparo do solo, escarificador, enxada rotativa, arado de aivecas, grade aradora e arado de discos, utilizando um perfilômetro, concluiu que entre escarificador, arado de aivecas e arado de disco não houve diferença no IR e entre a enxada rotativa e grade aradora também não houve diferença estatisticamente a 5% pelo teste Tukey.

Segundo ainda o mesmo autor, há necessidade de padronização da metodologia da determinação dos índices de rugosidade, para evitar a discussão e comparação de valores numéricos absolutos.

Coan (1995), trabalhando com os mesmos implementos, não observou diferenças estatisticamente significativas e destaca também que os maiores índices foram obtidos para o arado de aivecas, arados de discos e escarificador.

As formas de preparo que apresentaram maiores médias (Tabela 10) para o índice de rugosidade foram aquelas em que o solo foi menos preparado, ou seja, aquelas em que se usou apenas a aração ou aração e gradagem. Dependendo do tipo de solos estes implementos proporcionam uma maior rugosidade superficial, contribuindo para uma melhor conservação do solo, pois

como regra geral, quanto maior a rugosidade, menor é a propensão de ocorrer a erosão.

Segundo Volk et al. (2004), as microdepressões resultantes da rugosidade superficial são fundamentais para armazenar água da chuva e, assim, aumentar sua infiltração no solo, retardando a enxurrada e, conseqüentemente, reduzindo o escoamento superficial e sua capacidade erosiva.

4.3. Avaliação do sistema de aquisição de imagens

O sistema desenvolvido, constituído de dois circuitos, denominados de base terra e base remota, teve um bom desempenho, em relação a transmissão de sinais, sendo que em algumas vezes houve interferência no sinal recebido pela base remota, que disparava as câmeras sem ter tido o comando para fazê-lo. Os disparos das câmeras ocorreram de forma simultânea, no mesmo instante, capturando a mesma cena (Figura 21), tanto no modo manual como no automático.




Figura 21 – Imagens obtidas simultaneamente da mesma área, altura de 20 m: colorida (a); e infravermelho (b).

Os números das quantidades de imagens adquiridas pelo sistema mostrados no display da base terra, em alguns momentos foi diferente do

número de imagens obtidas pelas câmeras, fato ocorrido por causa de interferências no sinal emitido para a base remota.

4.4. Tamanho dos blocos da imagem

Na Tabela 10 estão apresentados os índices kappa, e a exatidão global para as imagens nas respectivas alturas usando diferentes tamanhos de blocos. De uma maneira geral o bloco com dimensão de 50x50 pixel apresentou menores valores do índice kappa em todas as alturas trabalhadas, 4, 20, 50 (Tabela 10).

Tabela 10 – Exatidão global (EG), índices kappa obtidos em diferentes tamanhos de blocos e alturas do balão

Altura	Bloco	Índice kappa	EG%
4 m	50 x 50	0,47 c	58,0
	150 x 150	0,73 b	79,0
	250 x 250	0,96 a	97,0
20 m	50 x 50	0,78 b	82,6
	150 x 150	0,99 a	99,6
	250 x 250	1,0 a	100
50 m	50 x 50	0,84 b	87,4
	90 x 90	0,98 a	99,0

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste z a 5% de probabilidade.

Na altura de 4 m, com a dimensão dos blocos de 50x50 pixel, a classificação não foi satisfatória, uma vez que os valores do índice kappa foram na maioria abaixo de 0,50. Isto pode ser devido ao fato de que blocos com dimensões maiores, abrangem maior região contendo maiores 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, 150x150 ou 250x250 pixel neste caso, seria pelo tempo e o uso de memória do sistema para o processamento. O tempo de processamento gasto para os blocos 150x150 pixel foi de 503 segundos (aproximadamente 8'38'') e para os blocos 250x250 pixel 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 250x250 pixel, com exatidão global igual a 100% (Tabela 11).

Em relação aos blocos 50x50 e 90x90 pixel para imagens a 50 m de altura, houve diferença estatística entre os valores do índice kappa, sendo que o bloco de 90x90 apresentou maior valor, 0,98, exatidão global de 99% e tempo de processamento de 508 segundos (aproximadamente 8'46'') e para os blocos de 50x50 pixel, índice kappa de 0,84 e tempo de processamento foi de 509 segundos (aproximadamente 8'48'').

Com base nos gráficos apresentados na Figura 22, para imagens captadas a 4 m de altura, percebe-se que com o aumento da dimensão dos blocos, há uma tendência de aumentar a freqüência dos valores grandes para o índice kappa aumentar, ou seja, há uma melhora na exatidão do classificador, 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 (9x9, 13x13 e 17x17 pixels) e verificaram que os mesmos influenciam no tempo de processamento e na acurácia da classificação, sendo que o bloco maior foi o que apresentou os melhores resultados.

Para a altura de 20 m, houve um comportamento semelhante ao ocorrido nas imagens com 4 m de altura, o aumento da dimensão dos blocos apresentou uma tendência de aumentar a freqüência dos maiores valores do índice kappa, como pode ser observado na Figura 23.

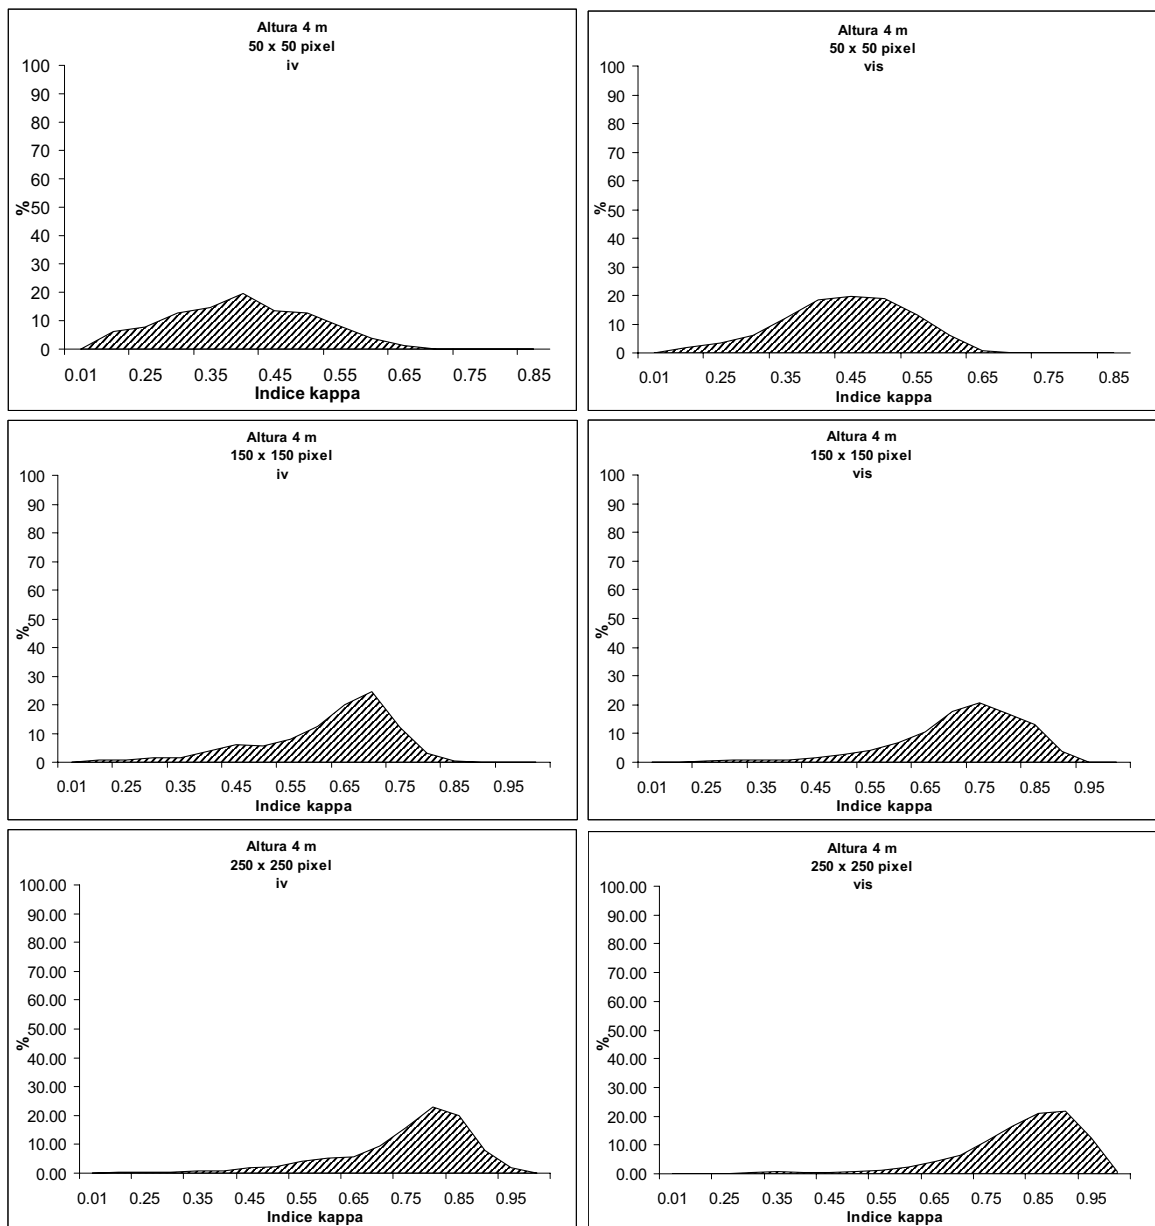


Figura 22 – Gráficos de frequência dos valores do índice kappa dos blocos 50x50, 150x150 e 250x250, pixel na altura de 4 m, das imagens infravermelho (iv) e coloridas (vis).




Figura 23 – Gráficos de freqüência dos valores do índice kappa dos blocos 50x50, 150x150 e 250x250, pixel na altura de 20 m, das imagens infravermelho (iv) e coloridas (vis).

Os blocos 150x150 e 250x250 pixel, na altura de 20 m, tiveram a maioria dos valores acima de 0,85, tanto na imagem colorida como na imagem infravermelha, porém o bloco 250x250 apresentou uma 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 pequenas, e nas menores alturas, o cálculo dos descritores texturais para determinada classe, fica restrita ao objeto representado na imagem. No caso das imagens adquiridas a 4 m, tanto o bloco de 50x50, 150x150 pixel, apresentam parte de um ou poucos torrões da parcela, sendo que os descritores texturais serão calculados com base apenas nestes torrões, não obtendo informações de toda a classe.

Shaban e Dikshit (1998) relatam que blocos com dimensões pequenas são altamente variáveis para expressar as propriedades características de cada classe em consideração.

Os mesmos autores citam que qualquer aumento no tamanho do bloco que não seja o ótimo, provavelmente tornará o processo computacionalmente mais custoso, sem prover qualquer melhoria na precisão, podendo também levar a interpretações incorretas pelo fato de englobar mais do que uma classe de textura.

Os descritores texturais devem identificar unicamente uma região de textura, ou uma classe, assim em blocos com dimensões pequenas, os descritores texturais não serão representativos da classe em questão, tendo como consequência uma classificação com baixo índice de acerto.

Segundo Silva (2008), para que regiões de uma imagem sejam corretamente classificadas é preciso que o tamanho dos blocos seja grande o suficiente para a obtenção dos padrões texturais.

De acordo com os gráficos apresentados na Figura 24, em relação ao bloco 50x50 na altura de 50 m, comparando com o bloco 90x90 pixel, percebe-se que há uma maior amplitude nos valores do índice kappa, por outro lado, no bloco 90x90 há uma maior concentração dos valores do índice kappa acima de 0,85.

Na altura de 100 m observa-se que há uma maior porcentagem dos índices kappa acima de 0,95 na imagem colorida do que na imagem infravermelha (Figura 24).

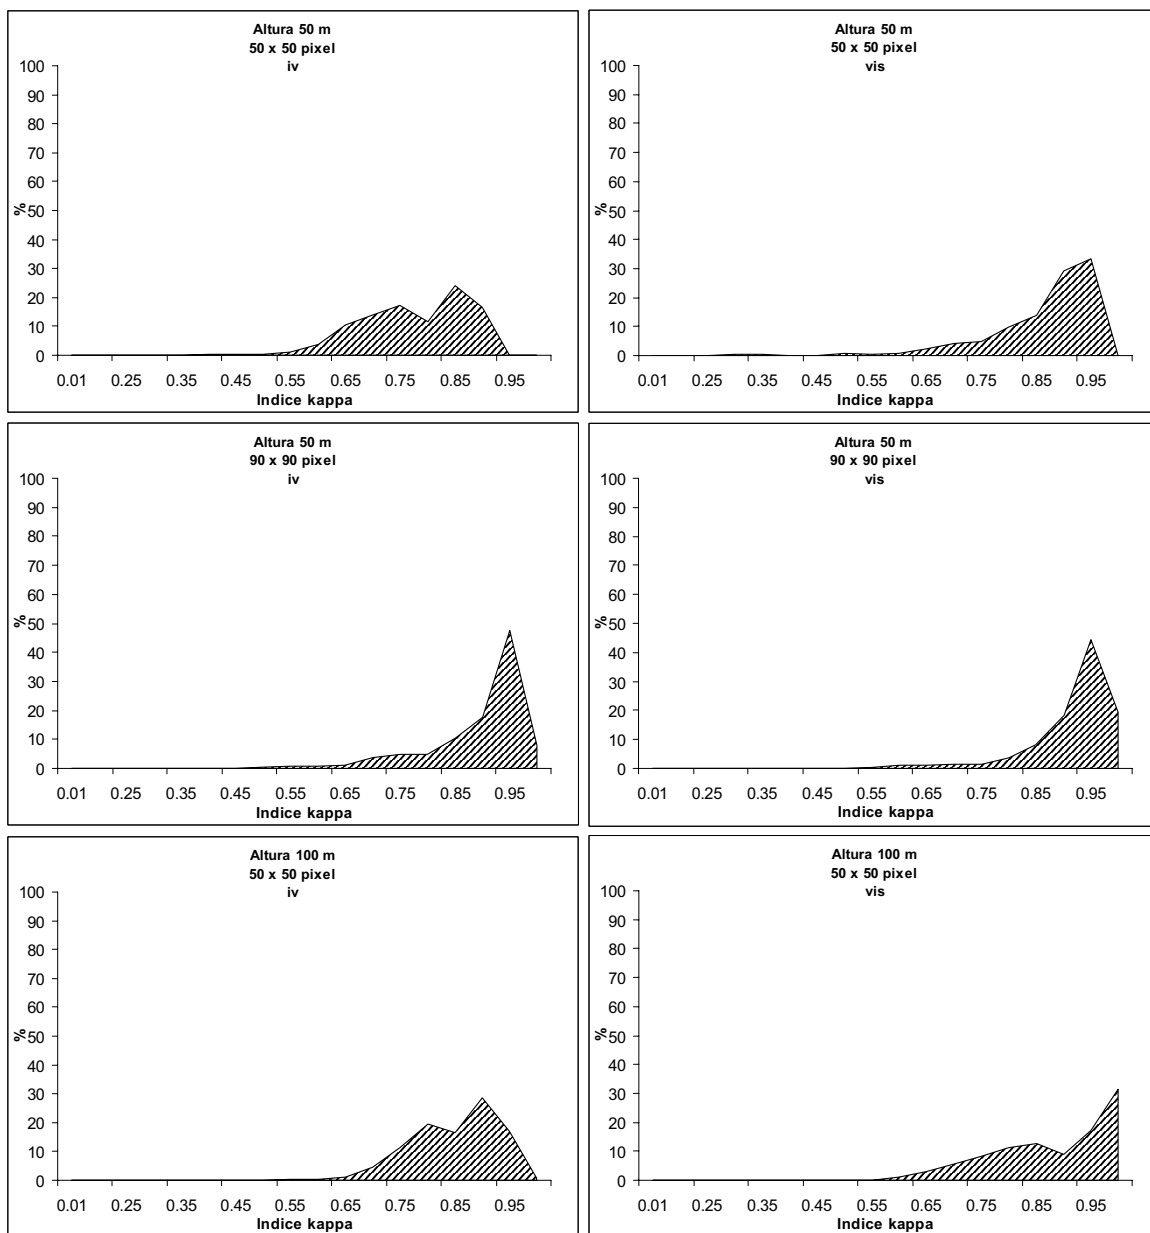


Figura 24 – Gráficos de frequência dos valores do índice kappa dos blocos 50x50, 90x90, altura de 50 m e 50x50 pixel na altura de 100 m, das imagens infravermelho (iv) e coloridas (vis).

Em todos os gráficos de freqüência dos valores dos índices kappa apresentados, percebe-se que com o aumento das dimensões dos blocos, e o aumento na altura de aquisição das imagens, há uma tendência no aumento de valores do índice kappa acima de 0,80, que é considerado como uma classificação muito boa.

O efeito do bloco, 50x50 na altura de 20 m, é o mesmo ocorrido na altura de 4 m, mas os blocos 150x150 e 250x250 pixels (Figura 25), representa uma maior área da parcela, ou seja, tem uma maior representação de determinada classe, se comparando com os blocos com mesma dimensão para altura de 4 m.




Figura 25 – Diferentes tamanhos de blocos: imagem colorida a 4 m de altura (a, b, c); imagem infravermelha a 20 m (d, e, f); 50x50 pixel (a, d); 150x150 pixel (b, e); e 250x250 pixel (c, f).

Orlando (2003) testou três diferentes tamanhos de blocos, para classificação de plantas daninhas, 17x17, 34x34 e 68x68 pixels, e concluiu que os melhores valores da exatidão global, ocorreram para o tamanho de bloco 68x68 pixels.

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 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 uma maior parte da área em estudo.

De acordo com o exposto acima, para as alturas de 4 e 20 m, optou-se pelo bloco 250x250 pixel e para altura de 50 m, 90x90 pixel, daqui por diante as análises serão realizadas apenas com estas dimensões, e para a altura de 100 m, 50x50 pixel (Figura 26).




Figura 26 – Exemplos de blocos 50x50 pixel, 90x90 pixel para imagens a 50 m (a, b) e bloco 50x50 pixel para imagens a 100 m (c).

Comparando os blocos de 50x50, na altura de 4 e 20 m (Figura 25), com os blocos de 50x50, a 50 e 100 m (Figura 26), percebe-se um maior número de torrões presentes na área do bloco, o mesmo ocorrendo com o bloco de 90x90 pixel, reforçando que com o aumento da dimensão dos blocos se obtém informações de textura da classe e não de pequenos torrões.

De acordo com Marceau et al. (1990), 90% da variabilidade na precisão de classificação usando textura dependem 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.

4.5. Ângulos da matriz de co-ocorrência

Nos quatro ângulos de orientação do pixel vizinho para o cálculo da matriz de co-ocorrência, observa-se que houve uma tendência dos valores do índice kappa ficarem acima de 0,75, este valor indica que a classificação foi 75% melhor do que a classificação ao acaso (Tabela 11).

Nas imagens coloridas adquiridas a 4 m, o ângulo de 135° apresentou 76,60% dos valores entre a faixa de 0,80 a 0,95, e entre 0,95 e 1,0, foi de 1,96%, índice de classificação considerado excelente. Nas imagens infravermelhas foi o ângulo 45°, que apresentou a maior porcentagem, 47,45%, dos valores do índice kappa na faixa de 0,80 a 0,95 (Figura 27).

Na Tabela 11, são apresentados os maiores valores encontrados do índice kappa e exatidão global, para cada ângulo nas imagens coloridas e infravermelhas com alturas de 4 m.

Observa-se que para as imagens coloridas há uma diferença estatisticamente apenas entre o ângulo de 135° e os demais, e é o que também apresenta maior exatidão global.

Para as imagens infravermelhas, não há diferença estatística entre os ângulos 0° e 90°, todos os demais são diferentes entre si, pelo teste z. O ângulo de 45° difere estatisticamente dos demais, com o maior valor do índice kappa e também maior valor da exatidão global.

Tabela 11 – Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 4 m

	Ângulo	Índice kappa	EG%
Colorida	0°	0.81 b	85
	45°	0.80 b	84.6
	90°	0.81 b	85.2
	135°	0.96 a	97
Infravermelha	0°	0.77 c	82
	45°	0.94 a	95.4
	90°	0.73 c	78.8
	135°	0.88 b	90

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste z a 5% de probabilidade.

Os valores do índice kappa para as imagens coloridas e infravermelhas para a altura de 20 m, estão apresentados na Tabela 12.

Tabela 12 – Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 20 m

	Ângulo	Índice kappa	EG%
Colorida	0°	0.98 b	98.4
	45°	1.0 a	100
	90°	0.99 ab	99.2
	135°	1.0 a	100
Infravermelha	0°	0.99 a	99.6
	45°	1.0 a	100
	90°	1.0 a	100
	135°	0.99 a	99.8

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste z a 5% de probabilidade.

Os índices kappa obtidos para as imagens coloridas nos ângulos 45°, 90° e 135° não foram diferentes estatisticamente, sendo que 45° e 135° tiveram valor igual a 1, sendo uma classificação 100% perfeita, sem erros. Como não houve diferença entre esses ângulos, optou por aquele que apresentasse uma frequência maior dos valores do índice kappa na faixa entre 0,95 e 1,0.

Nas imagens adquiridas a 20 m, todos os ângulos apresentaram mais que 70% dos valores do índice kappa entre 0,85 e 1,0, e o que apresentou a maior porcentagem, entre a faixa de 0,95 e 1,0, com 69,54%, foi o ângulo 135° para as imagens coloridas e o ângulo de 45° para imagens infravermelhas, com 67,45%, entre 0,95 e 1,00 (Tabela 13).

Tabela 13 – Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 50 m

	Ângulo	Índice kappa	EG%
Colorida	0°	0.95 a	96.2
	45°	0.97 a	98.2
	90°	0.95 a	96.4
	135°	0.92 b	93.6
Infravermelha	0°	0.96 b	97
	45°	0.99 a	99.6
	90°	0.99 a	99.2
	135°	0.99 a	99.2

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste z a 5% de probabilidade.

Os valores do índice kappa, e exatidão global para as imagens coloridas e infravermelhas, na altura de 50 m estão apresentados na Tabela 13. O mesmo procedimento usado em imagens adquiridas a 20 m para a definição do melhor ângulo foi aplicado para as imagens, coloridas e infravermelhas adquiridas a 50 m.

Os índices kappa obtidos, a partir de imagens coloridas, nos ângulos 0°, 45° e 90°, não diferem estatisticamente entre si.

Para as imagens infravermelhas, não houve diferença estatística entre os valores do índice kappa para os ângulos 45°, 90° e 135°, e todos apresentaram exatidão global igual a 99%.

Em relação as imagens adquiridas a 50 m, pode-se dizer o mesmo ocorrido com as imagens a 20 m, que o ângulo de 45° apresentou 25,62% dos valores do índice kappa entre 0,95 e 1,0, para imagem colorida e para as imagens infravermelhas, 80% dos valores ficaram acima de 0,85 em todos os ângulos, e o que apresentou maior % entre 0,95 e 1,0 foi o de 45°, com 54% dos valores nesta faixa (Figura 27).

Na Tabela 14, são apresentados os valores do índice kappa, diferenciados pelo teste z a 5%, e os valores da exatidão global para as imagens adquiridas a 100 m.

Nas imagens coloridas não foram detectadas diferenças significativas entre os índices kappa obtidos para os ângulos 0°, 45°, 90° e 135°. Os ângulos de 45°, 90° e 135° apresentaram exatidão global igual a 100%, a escolha então foi baseada no que apresentasse maior frequência de valores do índice kappa igual a 1,0.

Para ambas as imagens adquiridas a 100 m, observa-se que os valores do índice kappa também ficaram com mais de 60% dos índices acima de 0,85, e na faixa de 0,95 a 1,0 o ângulo de 135° foi que apresentou maior porcentagem, 29% para as imagens infravermelhas; e para as imagens coloridas o ângulo de 45° com 56,73% dos valores do índice kappa entre 0,95 e 1,0.

Em relação ao ângulo para as imagens infravermelhas, o que difere estatisticamente dos demais foi o ângulo de 135°, e que também apresenta maior % de valores kappa acima de 0,95.




Figura 27 – Gráficos de freqüência dos valores do índice kappa dos blocos, nas diferentes orientações, para as alturas de 4, 20, 50 e 100 m.

Tabela 14 – Valores do índice kappa e exatidão global para os ângulos 0°, 45°, 90° e 135°, para imagens a 100 m

	Ângulo	Índice kappa	EG%
Colorida	0°	0.99 a	99.8
	45°	1.0 a	100
	90°	1.0 a	100
	135°	1.0 a	100
Infravermelha	0°	0.97 b	97.6
	45°	0.95 bc	96.4
	90°	0.93 c	94.8
	135°	0.99 a	99.6

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, não diferem entre si pelo teste z a 5% de probabilidade.

4.6. Avaliação dos descritores

A classificação foi realizada utilizando as características selecionadas em tópicos anteriores: dimensão dos blocos para altura de 4 e 20 m, 250x250 pixel; para 50 m, 90x90 pixel e 100 m, 50x50 pixel; ângulo de orientação para o cálculo da matriz de co-ocorrência: imagens coloridas, 135° para as imagens adquiridas a 4, 20 e 100 m, e 45° para imagens adquiridas a 50 m: imagens infravermelhas, 45° para todas as imagens adquiridas e utilizando todas as combinações possíveis dos descritores texturais, no total de 255 combinações.

Na Figura 28, estão ilustrados exemplos de blocos de imagens coloridas e infravermelhas, que foram utilizados no processo de classificação, nas diferentes bandas, R, G, B para imagem colorida, IV R, IV G e IV B para imagem infravermelha, proveniente de uma imagem adquirida a 20 m e com dimensão do bloco de 250x250 pixel. Na figura os blocos não estão com o tamanho real.




Figura 28 – Exemplo das bandas de uma imagem: banda R (a); banda G (b); banda B (c); imagem colorida (d); banda IV R (e); banda IV G (f); banda IV B (g); e imagem infravermelha (h).

Na Tabela 15, estão apresentados os valores médios, máximo, mínimo e desvio padrão dos índices kappa para as diferentes alturas em diferentes bandas.

Como pode ser observado na Tabela 15, na altura de 20 e 100 m houve índice kappa máximo igual a 1,0, para as bandas R, B e IV B para a altura de 20 m e bandas B e G para a altura de 100 m, valor que, segundo Rosenfield e Fitzpatrick-Lins (1986), indica uma classificação perfeita.

Segundo Horta (2006), valores do índice kappa acima de 0,81 são considerados excelentes, observando os dados da Tabela 15, pode-se constatar que em todas as bandas, tanto na imagem colorida como na imagem infravermelha, em todas as alturas, os valores máximos ficaram acima de 0,81, ou seja, todos apresentaram o valor do índice kappa na faixa de classificação excelente.

Nas Figuras 29 e 30, são apresentados os gráficos de frequência dos valores do índice kappa para cada altura, utilizando as 255 combinações dos descritores texturais.

Nas imagens infravermelhas, há uma tendência das bandas IV G e IV B apresentarem melhores resultados nas diferentes alturas.

Kaelita et al. (2005), avaliando a umidade do solo por meio de técnicas de sensoriamento remoto, determinaram a possibilidade de estimar a umidade superficial do solo (0 a 7,6 cm) nas bandas do espectro do visível, (R, G, B) e do infravermelho próximos.

Krishnan (1980), ao estudar a identificação dos comprimentos de onda mais adequados para predizer o conteúdo de matéria orgânica do solo, concluiu que a região do visível proporcionou as melhores informações, com coeficiente máximo de correlação para os modelos estudados de 0,98 para as bandas na região de (G) 564 nm e (R) 623 nm, enquanto que na região do infravermelho, o coeficiente máximo de correlação foi 0,87.

Coleman e Montgomery (1987) obtiveram correlações significativas entre propriedades espectrais e teores de silte e argila do solo. Estes autores elegeram as regiões entre 450 e 520 nm (B e G), 520 e 600 nm (G), 630 e 690 nm (R) para estimar os teores de silte e as regiões 520 e 600 nm (G), 1150 e 1300 nm (infravermelho) como as melhores para estimar os teores de argila.

Tabela 15 – Dados estatísticos do índice kappa para os blocos de imagem adquirida a diferentes alturas

Bandas	N	4 m			20 m			50 m			100 m						
		Média	Mínimo	Máximo	Desvio-padrão	Média	Mínimo	Máximo	Desvio-padrão	Média	Mínimo	Máximo	Desvio-padrão				
B	255	0.82	0.32	0.96	0.11	0.94	0.51	1.00	0.08	0.91	0.49	0.97	0.08	0.92	0.54	1.00	0.10
G	255	0.78	0.20	0.95	0.11	0.93	0.39	0.99	0.11	0.91	0.56	0.97	0.07	0.93	0.54	1.00	0.09
R	255	0.81	0.19	0.95	0.12	0.93	0.46	1.00	0.09	0.90	0.46	0.96	0.07	0.88	0.45	0.98	0.10
IV B	255	0.72	0.16	0.88	0.15	0.91	0.22	1.00	0.12	0.93	0.49	0.98	0.06	0.78	0.54	0.85	0.04
IV G	255	0.77	0.10	0.94	0.15	0.93	0.23	0.99	0.11	0.90	0.53	0.99	0.10	0.91	0.50	0.99	0.08
IV R	255	0.73	0.21	0.91	0.13	0.92	0.25	0.99	0.12	0.89	0.40	0.99	0.11	0.90	0.52	0.98	0.08

N - número de combinações dos descritores utilizados.




Figura 29 – Gráfico de frequência do índice kappa, obtido com a avaliação dos descritores para as diferentes bandas e alturas, 4 e 20 m.




Figura 30 – Gráfico de frequência do índice kappa, obtido com a avaliação dos descritores para as diferentes bandas e alturas, 50 e 100 m.

A percentagem do índice kappa igual a 1,0 nas bandas R, B, IV B, para imagem de 20 m foram respectivamente, 7,45%, 9,41% e 7,45% e para as bandas B e G na imagem a 100 m, foram de 7,06% e 30,20%. A diferença entre esses índices foi na combinação dos descritores utilizados (Figuras 27 e 28).

4.6.1. Avaliação das combinações dos descritores nas diferentes bandas de imagens coloridas e infravermelhas

A exatidão global para os maiores índices kappa obtidos de imagens a altura de 4 m, encontrados em cada banda estão representados nas Tabelas 16 e 17.

Tabela 16 – Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas, altura da câmera a 4 m

Descritores utilizados	IV R		Descritores utilizados	IV G		Descritores utilizados	IV B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
1;2;3;4;5;6;7;8	93.20	0.91 a B	2;4;6;7;8	95.40	0.94 a A	1;2;3;4;5;7;8	91.00	0.88 a B
1;2;3;5;6;7;8	92.00	0.90 a B	2;4;5;6;7;8	95.40	0.94 a A	1;2;3;4;5;6;7;8	90.20	0.87 a B
1;2;3;4;5;6;7	91.60	0.89 a B	2;3;5;6;7;8	95.00	0.93 a A	2;3;5;6;7;8	90.00	0.87 a B
1;2;3;4;5;6	91.20	0.89 a B	2;3;4;5;6;7;8	94.60	0.93 a A	1;3;5;6;7;8	89.80	0.87 a B
1;2;3;5;6;7	90.80	0.88 a B	3;5;6;8	94.40	0.93 a A	1;3;4;5;6;7;8	89.80	0.87 a B

Valores de kappa seguidos por uma mesma letra, minúscula na coluna, e maiúscula na linha não diferem entre si pelo teste z a 5% de probabilidade. Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

Tabela 17 – Resultados da exatidão global (EG), valores kappa para as bandas das imagens coloridas, altura da câmera a 4 m

Descritores utilizados	R		Descritores utilizados	G		Descritores utilizados	B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
1;2;3;4;5;6;7;8	96.20	0.95 a A	2;3;5;6;7;8	96.00	0.95 a A	1;2;3;4;5;7	93.20	0.96 a A
1;2;3;5;7;8	96.00	0.95 a A	1;2;3;5;6;7;8	95.20	0.94 a A	1;2;3;4;5;7;8	92.00	0.96 a A
1;2;3;5;6;7	95.60	0.94 a A	2;3;5;6;7	94.80	0.93 a A	3;4;5;7;8	91.60	0.95 a A
1;2;3;5;8	95.20	0.94 a A	3;4;5;6;7;8	94.40	0.93 a A	3;4;5;6;7	91.20	0.95 a A
1;2;3;6;8	95.00	0.93 a A	2;3;5;7;8	94.00	0.92 a A	2;3;4;5;7;8	90.80	0.95 a A

Valores de kappa seguidos por uma mesma letra minúsculas na coluna, e maiúscula na linha não diferem entre si pelo teste z a 5% de probabilidade. Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

Nas bandas das imagens infravermelhas, observa-se uma diferença estatística entre os índices kappa, entre as bandas IV G com as demais bandas, IV R e IV B, apresentado os maiores valores do índice kappa e exatidão global.

Não houve diferença estatística entre os descritores analisados, dentro de cada banda, indicando que não há diferença entre as combinações dos descritores testados, nem entre as diferentes bandas analisadas, como pode ser observado nas Tabelas 16 e 17.

Segundo Rennó (2003), alguns dos descritores texturais podem apresentar maior variação entre classes do que dentro das classes e, portanto,

a seleção destas variáveis deve promover uma melhor discriminação entre as classes consideradas.

Ainda o mesmo autor conclui que as medidas de textura melhoram significativamente a precisão da classificação de imagens SAR. No entanto, não há um conjunto destas medidas que se possa generalizar como sendo ideal para estudos de discriminação de alvos agrícolas.

Ulaby et al. (1986), utilizando imagens Seasat, selecionaram duas medidas de Haralick, contraste e homogeneidade, que melhor separaram as classes de uso estudadas. Os melhores resultados foram conseguidos com o uso simultâneo dos parâmetros contraste e homogeneidade. Os mesmos autores, procurando discriminar cinco tipos de florestas a partir de imagens SIR-A, conseguiram classificações com precisão total superior a 90% quando a média e o contraste foram utilizados.

Briand e Gray (1989) mostraram que medidas de textura de primeira ordem (variância, coeficiente de correlação, assimetria) podem ser utilizadas para melhorar a identificação de classes de uso em imagens SAR. Quando somente a informação tonal foi utilizada, a precisão total foi de 60%, subindo para 85% quando se utilizou também a informação textural.

A Tabela 18 apresenta a matriz de confusão para os maiores valores do índice kappa das bandas IV G e B para as imagens infravermelhas e para as imagens coloridas, respectivamente, para a altura de 4 m. A matriz de confusão mostra os erros e acertos do classificador, na diagonal da matriz está o número de acertos, ou seja, quantas amostras foram classificadas corretamente dentro de cada classe.

Para a altura de 20 m, não houve diferença estatística entre a maioria dos valores dos índices kappa nas bandas IV R, IV B e IV G, apenas em dois valores houve essa diferença, na banda IV G. As bandas IV R e IV B apresentaram valores do índice kappa iguais a 1,0, índice que é considerado excelente para efeito de classificação (Tabela 19).

Tabela 18 – Representação da matriz de confusão: A - matriz de classificação para IV G e B - matriz de classificação para banda B

Classes	A						B							
	1	2	3	4	5	N	1	2	3	4	5	N		
1 - Muito baixa	98	0	0	0	2	100	99	0	1	0	0	100		
2 - Baixa	1	99	0	0	0	100	3	97	0	0	0	100		
3 - Média	3	1	96	0	0	100	1	0	99	0	0	100		
4 - Alta	4	0	3	89	4	100	0	0	0	95	5	100		
5 - Muito alta	0	1	0	4	95	100	0	1	0	4	95	100		
	EG – 95.40%					477	500	EG – 93.20%					485	500

N – números de amostras de cada classe. 1, 2, 3, 4 e 5 são as classes de rugosidade do solo.

Tabela 19 – Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas e coloridas, altura da câmera a 20 m

20 m - INFRAVERMELHO								
Descritores utilizados	IV R		Descritores utilizados	IV G		Descritores utilizados	IV B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
1;5;6;8	100.00	1.0 a A	2;3;5	99.80	0.99 a A	3;6;7;8	100.00	1.0 a A
1;4;6;8	100.00	1.0 a A	6;7;8	99.60	0.99 a A	2;6;7;8	100.00	1.0 a A
1;4;5;6;8	100.00	1.0 a A	3;4;7	99.40	0.99 a A	2;3;6;8	100.00	1.0 a A
1;3;5;7;8	100.00	1.0 a A	2;7;8	99.20	0.99 a B	1;6;7;8	100.00	1.0 a A
1;3;5;6;8	100.00	1.0 a A	4;6;8	99.00	0.98 a B	1;3;5;8	100.00	1.0 a A

20 m - COLORIDA								
Descritores utilizados	IV R		Descritores utilizados	IV G		Descritores utilizados	IV B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
1;6;8	99.80	0.99 a A	2;7;8	99.60	0.99 a A	4;5;6;8	100.00	1.0 a A
1;3;5	99.60	0.99 a A	2;3;5	99.40	0.99 a A	2;6;7;8	100.00	1.0 a A
3;7;8	99.40	0.99 a AB	2;4;6	99.20	0.99 a B	3;4;5;7;8	100.00	1.0 a A
5;7;8	99.20	0.99 a B	2;4;7;8	99.00	0.98 a B	3;4;5;6;8	100.00	1.0 a A
5;6;7;8	99.00	0.98 a B	7;8	98.80	0.98 a B	2;3;5;7;8	100.00	1.0 a A

Valores de kappa seguidos por uma mesma letra minúsculas na coluna, e maiúscula na linha não diferem entre si pelo teste z a 5% de probabilidade. Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

A Tabela 20 apresenta a matriz de confusão para os maiores valores do índice kappa encontrados, para as imagens coloridas e infravermelhas, que no caso foi igual a 1,0, sendo considerado uma classificação perfeita, com exatidão global igual a 100%.

Tabela 20 – Matriz de confusão para valor de kappa igual a 1,0, nas bandas IV R, IV B e B, para altura de 20 m

Classes	1 - Muito baixa	2 - Baixa	3 - Média	4 - Alta	5 - Muito alta	N
1 - Muito baixa	100	0	0	0	0	100
2 - Baixa	0	100	0	0	0	100
3 - Média	0	0	100	0	0	100
4 - Alta	0	0	0	100	0	100
5 - Muito alta	0	0	0	0	100	100
		EG – 100%			500	500

N - número de amostras total da classe.

Isto pode ter ocorrido devido as imagens adquiridas em alturas maiores, apresentarem mais uniformidade, ou seja, menor variabilidade nas características texturais da imagem, para cada classe de rugosidade, pois possuem maior área da parcela experimental, do que imagens com alturas mais baixas, que contem apenas uma parte da parcela.

Na Tabela 21 são apresentados os valores do índice kappa, exatidão global, combinações dos descritores utilizados para cada banda das imagens coloridas e infravermelhas, com as câmeras digitais a 50 m do solo.

Entre as bandas R, G e B das imagens coloridas não houve diferença estatística entre os índices kappa, sendo que a banda B apresentou valores maiores de exatidão global.

Nas bandas IV R, IV B e IV G, também não houve diferença estatística entre os índices kappa.

Tabela 21 – Resultados da exatidão global (EG), valores do índice kappa para as bandas das imagens infravermelhas e coloridas, altura da câmara a 50 m

50 m – INFRAVERMELHO								
Descritores utilizados	IV R		Descritores utilizados	IV G		Descritores utilizados	IV B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
2;3;5;8	99.80	0.99 a A	2;3;5;6	99.60	0.99 a A	1;2;6;7	99.00	0.98 a A
2;3;5;6;8	99.60	0.99 a A	2;3;4;8	99.60	0.99 a A	1;2;3;5	98.80	0.98 a A
2;3;5	99.40	0.99 a A	2;3;5	99.40	0.99 a A	2;5;7;8	98.60	0.98 a A
2;3;8	99.20	0.99 a A	1;2;7	99.20	0.99 a A	2;3;8	98.40	0.98 a A
2;5;7	99.00	0.98 a A	2;4;5;6	99.00	0.98 a A	2;5;8	98.20	0.97 a A

50 m - COLORIDA								
Descritores utilizados	R		Descritores utilizados	G		Descritores utilizados	B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
3;4;5;6;7	96.60	0.95 a A	2;4;5;7;8	97.60	0.97 a A	2;4;7;8	98.20	0.97 a A
2;3;5;6;7	96.40	0.95 a A	2;4;7	97.40	0.96 a A	2;4;5;7;8	98.00	0.97 a A
3;4;5;7	96.20	0.95 a A	2;4;6;7	97.20	0.96 a A	2;3;6;7;8	97.80	0.97 a A
2;5;7;8	96.00	0.95 a A	3;4;7;8	97.00	0.96 a A	2;3;7	97.60	0.97 a A
1;7;8	95.80	0.94 a A	1;2;4;8	96.80	0.96 a A	3;4;6;7	97.40	0.96 a A

Valores de kappa seguidos por uma mesma letra minúsculas na coluna, e maiúscula na linha não diferem entre si pelo teste z a 5% de probabilidade. Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

Segundo Shaban e Dikshit (1998), em se tratando de imagens espectrais, o uso de diferentes bandas espectrais para o cálculo de características de textura (descritores texturais) não produz resultados estatisticamente diferentes de classificação.

Em relação entre as bandas das imagens coloridas com as das imagens infravermelhas, Tabela 21, não houve diferença estatística entre os índices kappa, apenas os valores de exatidão global nas bandas IV R, IV G e IV B foram superiores aos valores encontrados para as bandas R, G e B.

Como pode ser observado na Tabela 22, as bandas IV R e IV G, foram estatisticamente diferentes da banda IV B, apresentado os maiores valores do índice kappa e de exatidão global, e entre valores do índice kappa dentro de cada banda não houve diferença estatística tanto para imagens infravermelhas como coloridas, para altura de 100 m.

Tabela 22 – Resultados da exatidão global (EG), valores kappa para as bandas das imagens infravermelhas e coloridas, altura da câmera a 100 m

100 m - INFRAVERMELHO								
Descritores utilizados	IV R		Descritores utilizados	IV G		Descritores utilizados	IV B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
2;4;6;7;8	98.80	0.98 a A	2;3;5;7;8	99.60	0.99 a A	2;3;4;5;6;7	88.00	0.85 a B
2;3;6;7;8	98.60	0.98 a A	1;2;6;8	99.40	0.99 a A	2;3;5;6;7	87.80	0.84 a B
2;6;7;8	98.40	0.98 a A	2;4;6;8	99.20	0.99 a A	1;3;4;5;6;8	87.40	0.84 a B
1;2;6;8	98.20	0.97 a A	1;2;4;8	99.00	0.98 a A	2;3;6;7;8	87.20	0.84 a B
2;6;8	98.00	0.97 a A	2;3;6;8	98.80	0.98 a A	1;2;3;5;6	87.00	0.83 a B

100 m – COLORIDA								
Descritores utilizados	R		Descritores utilizados	G		Descritores utilizados	B	
	E.G%	kappa		E.G%	kappa		E.G%	kappa
2;3;8	98.80	0.98 a B	2;8	100.00	1.0 a A	2;5;7	100.00	1.0 a A
2;4;7;8	98.60	0.98 a B	2;3;7	100.00	1.0 a A	2;5;7;8	100.00	1.0 a A
2;8	98.40	0.98 a B	2;3;8	100.00	1.0 a A	2;5;6;8	100.00	1.0 a A
2;6;8	98.20	0.98 a B	2;4;7	100.00	1.0 a A	2;5;6;7	100.00	1.0 a A
2;4;8	98.00	0.97 a B	2;4;8	100.00	1.0 a A	2;4;5;8	100.00	1.0 a A

Valores de kappa seguidos por uma mesma letra minúsculas na coluna, e maiúscula na linha não diferem entre si pelo teste z a 5% de probabilidade. Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

Em relação às bandas R, G e B, pode-se observar pela Tabela 22, que entre as bandas G e B não houve diferença estatística, e que apresentaram valores do índice kappa igual a 1,0, e exatidão global 100%, sendo considerado uma classificação perfeita (Tabela 20).

Observando as colunas com as combinações dos descritores utilizados para a classificação nas Tabelas 16, 17, 19, 21 e 22, há certa tendência no uso de menor número de descritores, à medida em que a altura aumenta, assim para a altura de 4 m, os maiores valores de kappa foram conseguidos com combinações a partir de cinco até o máximo de oito descritores, na altura de 20 o número máximo de descritores utilizados em combinação foi de 5, o mesmo ocorrendo nas alturas de 50 e 100 m.

4.7. Correlação do índice de rugosidade superficial do solo com os descritores texturais da imagem

Os coeficientes da correlação de Pearson entre os índices de rugosidade e os descritores texturais estão apresentados na Tabela 23.

Tabela 23 – Valores dos coeficientes de correlação de Pearson, entre índice de rugosidade e os descritores texturais

Altura (m)		Descritores texturais								
		1	2	3	4	5	6	7	8	
20	Bandas	IV B	-0.416	-0.898	0.998	0.749	0.998	-0.399	-0.580	0.783
		B	-0.349	0.643	-0.470	-0.458	-0.493	-0.498	0.312	-0.480
100	Bandas	B	0.630	0.719	-0.459	-0.666	-0.435	0.572	0.578	-0.544
		IV G	0.602	0.620	-0.441	-0.690	-0.426	0.560	0.560	-0.546

Os descritores utilizados são: 1 - momento angular; 2 - média; 3 - variância; 4 - entropia; 5 - correlação; 6 - momento do produto; 7 - momento inverso da diferença e 8 - medidas de correlação.

O coeficiente de correlação de Pearson é uma medida do grau de relação linear entre duas variáveis quantitativas. Este coeficiente varia entre os valores -1 e +1. O valor 0 (zero) significa que não há relação linear, o valor +1 indica uma correlação linear direta perfeita e o valor -1 indica uma correlação linear perfeita, mas inversa, ou seja, quando uma das variáveis aumenta a outra diminui. Quanto mais próximo estiver de +1 ou -1, mais forte é a associação linear entre as duas variáveis (SANTOS, 2007).

Observa-se na Tabela 23, que o coeficiente de correlação não apresentou nenhuma tendência, pois foram observados tanto valores positivos quanto negativos, com exceção dos valores da banda B, na altura de 20 m, que apresentou tendência de correlação inversa do índice de rugosidade com os descritores texturais.

Os descritores 3 e 5, na banda IV B, apresentaram uma alta correlação com valores positivos, ou seja, tiveram uma correlação direta com o índice de

rugosidade, por outro lado, o descritor textural 2, apresentou alta correlação inversa com o índice de rugosidade.

Na banda B, na altura de 20 m, com exceção do descritor 2, os demais apresentaram um coeficiente de correlação baixo com tendência há uma correlação linear inversa.

Para as bandas B e IV G das imagens a 100 m, observa-se um comportamento semelhante dos coeficientes de correlação, os descritores 1, 2, 6 e 7 apresentam uma correlação direta e os descritores 3, 4, 5 e 8 correlação inversa com o índice de rugosidade.

Schimdt (1975), com base no valor numérico absoluto observado para o coeficiente de correlação classificou a relação linear entre duas variáveis em cinco categorias: desprezível (0,00 a 0,29); baixo (0,30 a 0,49); moderado (0,50 a 0,79); alto (0,80 a 0,99) e perfeito (1,00). Basicamente, todo e qualquer coeficiente de correlação superior a 80 % (0,80) revela que a reta é representativa dos pontos levantados (VANNI, 1998).

Analisando apenas os valores absolutos dos coeficientes de correlação apresentados na Tabela 23, observa-se uma tendência da correlação ser alta dos descritores texturais com o índice de rugosidade para a banda IV B e para a banda B há uma tendência de baixa correlação, para as imagens a 20 m.

Para as imagens a 100 m, observa-se uma tendência do coeficiente de correlação entre os descritores texturais e o índice de rugosidade, ser moderado tanto na banda B como na IV G.

5. CONCLUSÕES

Com base nos resultados encontrados nas condições do experimento conclui-se:

- a metodologia de medição do índice de rugosidade pelo perfilômetro de hastes utilizado não permitiu diferenciar os cinco diferentes índices das classes de rugosidade, com apenas duas classes estatisticamente diferentes;
- o sistema de aquisição de imagens desenvolvido é viável para utilização em sensoriamento remoto;
- o aumento da dimensão dos blocos das imagens, proporciona uma melhora significativa no processo de classificação das imagens, tanto para as imagens coloridas como para imagens infravermelhas;
- em todas as bandas das imagens coloridas e infravermelhas obtiveram valores do índice kappa acima de 0,85;
- os descritores utilizados no processo de classificação proposto, se mostraram confiáveis para o estudo da rugosidade superficial do solo;
- o classificador discriminou as 5 classes de rugosidade superficial do solo;
- o uso de imagens digitais conseguiu discriminar as 5 classes de rugosidade superficial do solo;
- o índice de rugosidade tendeu a uma correlação moderada a alta com os descritores texturais utilizados no processo de classificação.

REFERÊNCIAS

ALLMARAS, R.R.; BURWELL, R.E.; LARSON, W.E.; HOLT, R.F.; NELSON, W.W. **Total porosity and random roughness of the interrow zone as influenced by tillage**. Washington: USDA, 1966. 22 p.

ALVAREZ, V.H.; NOVAIS, R.F.; BARROS, N.F.; CANTARUTTI, R.B.; LOPES, A.S. Interpretação dos resultados das análises de solos. In: **Recomendação para o uso de corretivos e fertilizantes em Minas Gerais: 5.ª aproximação**. Viçosa: UFV, 1999.

ARAÚJO, J.C.; VETTORAZZI, C.A.; MOLIN, J.P. Determinação de zonas de manejo e estimativa da produtividade de culturas de grãos por meio de videografia aérea digital multiespectral. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2004, Piracicaba. **Anais...** Piracicaba: CONBAP, 2004.

BALLOIDE-PHOTO. Disponível em: <<http://www.balloide-photo.es/>>. Acesso em: 16 jul. 2007.

BARBOSA, H.A.; ROANHORSE, A.S. Mapeamento da cobertura vegetal por meio de aeronave não tripulada na estação experimental de Santa Rita em Arizona: estudo de caso. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. **Anais...** INPE, 2007. p. 6323-6328.

BERTOL, I. Perdas de nutrientes por erosão hídrica em diferentes sistemas de manejo de solo sob rotação de culturas. **Univ. Des.**, v. 2, p. 174-184, 1994.

BERTOL, I.B.; MELLO, E.L.; GUADAGNIN, J.C.; ZAPAROLLI, A.L.V.; CARRAFA, M.R. Nutrient losses by water erosion. **Sci. Agr.**, v. 60, p. 581-586, 2003.

BERTOL, I.; MELLO, E.L.; COGO, N.P.; VÁZQUEZ, E.V.; PAZ GONZÁLEZ, A. Parâmetros relacionados com a erosão hídrica sob taxa constante da enxurrada, em diferentes métodos de preparo do solo. **R. Bras. Ci. Solo**, v. 30, p. 715-722, 2006.

BERTOLANI, F.C.; GONZÁLEZ, A.P.; LIÑARES, M.L.; VÁZQUEZ, E.V.; MIRANDA, J.G.V.M. Variabilidade espacial da rugosidade superficial do solo medida com rugosímetros de agulhas e laser. **Bragantia**, Campinas, v. 59, n. 2, p. 227-234, 2000.

BOLLER, W.; GAMERO, C.A.; PEREIRA, J.O. Avaliação de diferentes sistemas de preparo e de condições de cobertura do solo. **Engenharia Agrícola**, Jaboticabal, v. 17, n. 2, p. 52-63, 1997.

BRIAND, P.; GRAY, J.T. Classification de l'utilisation du territoire sur une image radar SIR-B, à partir de l'information texturale dérivée des statistiques de premier ordre. In: IGARSS'89 - CANADIAN SYMPOSIUM ON REMOTE SENSIN, 12, 1999, Vancouver. **Proceedings...** New York: IEEE, 1989. v. 5, p. 2777-2780.

BURWELL, R.E.; LARSON, W.E. Infiltration as influenced by tillage induces random roughness and porespace. **Soil Sci. Am. Proc.**, Madison, v. 33, p. 449-452, 1969.

CANZIAN, E. **Comunicação serial – RS232**. Disponível em: <<http://www.eletronicosonline.com/dnc9.html>>. Acesso em: abr. 2004.

CARVALHO FILHO, A.C. **Alterações em latossolo vermelho e na cultura da soja em função de sistemas de preparo**. 2004. Tese (Doutorado) – Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, 2004.

CASTRO, J.; MARTINS, L.; ARANHA, J.; MACEDO, F. Sistema de navegação para fotografia aérea de pequeno e médio formato. **Silva Lusitana**, Portugal, v. 12, n. 2, p. 213-225, 2004.

CASTRO, L.G.; COGO, N.P.; VOLK, L.B.S. Alterações na rugosidade superficial do solo pelo preparo e pela chuva e sua relação com a erosão hídrica. **Revista Brasileira de Ciência do Solo**, v. 30, p. 339-352, 2006.

COAN, O. **Sistemas de preparo de solo: efeitos sobre a camada mobilizada e no comportamento das culturas do feijoeiro (*Phaseolus vulgaris* L.) e do milho (*Zea mays* L.), conduzidas em rotação**. 1995. Tese (Doutorado) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, SP.

COGO, N.P. **Effect of residue cover, tillage induce roughness, and slope lenght on erosion and related parameters**. 1981. 346 p. Dissertação (Mestrado) – Purdue University, West Lafayette, USA.

COGO, N.P.; MOLDENHAUER, W.C.; FOSTER, G.R. Soil loss reductions from conservation tillage practices. **Soil Sci. Soc. Am. J.**, v. 48, p. 368-373, 1983.

COLEMAN, T.L.; MONTGOMERY, O.L. Soil moisture, organic matter and iron content effect on the spectral characteristics of selected vertisols and alfisols in Alabama. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 53, p. 1659-1663, 1987.

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.

CONGALTON, R.G.; MEAD, R.A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 49, n. 1, p. 69-74, 1983.

DALLMEYER, A.U. **Eficiência energética e operacional de equipamentos conjugados de preparo de solo**. 1994. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, SP.

DEMATTÊ, J.A.M.; MORETTI, D.; VASCONCELOS, A.C.F.; GENÚ, A.M. Uso de imagens de satélite na discriminação de solos desenvolvidos de basalto e arenito na região de Paraguaçu Paulista. **Pesquisa Agropecuária Brasileira**, Brasília, v. 40, n. 7, p. 697-706, jul. 2005.

DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern classification**. New York: Wiley, 2001. v. 2, 654 p.

ELTZ, F.L.F.; NORTON, D. Surface roughness changes as affected by rainfall erosivity, tillage, and canopy cover. **Soil Sci. Soc. Am. J.**, v. 61, p. 1746-1755, 1997.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. Serviço Nacional de Levantamento e Conservação de Solos. **Manual de métodos de análise do solo**. Rio de Janeiro, 1979. 58 p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Manual de métodos de análise de solo**. 2.ed. Rio de Janeiro: Centro Nacional de Pesquisa de Solos, 1997. 212 p.

ENGESAT. Disponível em: <<http://www2.engesat.com.br/?system=news&action=read&id=587>>. Acesso em: 12 jul. 2007.

EVERITT, J.H.; ESCOBAR, D.E.; GERBERMANN, A.H.; ALANIZ, M.A. Detecting saline soils with video imagery. **Photogrammetric Engineering and Remote Sensing**, v. 54, p. 1283-1287, 1988.

EVERITT, J.H.; ESCOBAR, D.E., CAVAZOS, I.; DAVIS, M.R. A three-camera multispectral digital video imaging system. **Remote Sens. Environ.**, v. 54, p. 333-337, 1995.

FERREIRA, M.E.; ANDRADE, L.R.M.; SANO, E.E.; CARVALHO, A.M.; JUNQUEIRA, N.T.V. Uso de imagens digitais na avaliação da cobertura do solo. **Bol. Pesq. Desenv. – Embrapa Cerrados**, Planaltina, n. 21, p. 1-50, 2001.

FIGUEIREDO, D. **Conceitos básicos de sensoriamento remoto**. Brasília: CONAB, 2005.

GAMERO, C.A.; BENEZ, S.H. Avaliação da condição do solo após a operação de preparo. In: SILVEIRA, G.M. **IV Ciclo de Estudos sobre Mecanização Agrícola**. Jundiaí: Fundação Cargill, 1990. p. 12-21.

GE, Y.; THOMASSON, J.A.; SUI, R. **Remote sensing of soil properties in precision agriculture: a review**. 2006. (ASABE Meeting Presentation, 1176).

GOMES, O.F.M. **Processamento e análise de imagens aplicadas à caracterização automática de materiais**. 2001. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ.

GONZÁLEZ, R.C.; WOODS, R.E. **Processamento de imagens digitais**. São Paulo: Edgard Blücher, 2000. 509 p.

GUADAGNIN, J.C.; BERTOL, I.; CASSOL, P.C.; AMARAL, A.J. Perdas de nitrogênio por erosão hídrica em diferentes sistemas de manejo em um cambissolo húmico alumínico léptico. **R. Bras. Ci. Solo**, 2003.

HARALICK, R.M. Texture features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 3, n. 6, 1973.

HASEGAWA, J.K.; IMAI, N.N.; CAMARGO, P.O. Sistema de aquisição e processamento de dados georreferenciados para aplicações em agricultura de precisão. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO, 2004, Florianópolis. **Anais...** Florianópolis: UFSC, 2004.

HORTA, I.M.F. **Levantamento dos solos e ocupação da superfície do município de Nazareno, MG**. 2006. Dissertação (Mestrado) – Universidade Federal de Lavras, Lavras, MG.

HUANG, C. Sediment regimes under different slope and surface hydrologic conditions. **Soil Sci. Soc. Am. J.**, v. 62, p. 423-430, 1998.

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.

JAIN, A.K.; DUIN, R.P.W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 437, 2000.

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

JENSEN, J.R. Thematic information extraction: image classification. In: **Introductory digital image processing**. 2.ed. New Jersey: Prentice Hall, 1996. p. 197-252.

JENSEN, T.; APAN, A.; YOUNG, F.; ZELLER, L. Detecting the attributes of a wheat crop using digital imagery acquired from a low-altitude platform. **Computers and Electronics in Agriculture**, v. 59, p. 66-77, 2007.

JOHNSON, R.A.; WICHERN, D.W. **Applied multivariate statistical analysis**. New Jersey: Prentice Hall, 1998. 816 p.

KAMPHORST, E.C.; JETTEN, V.; GUERIF, J.; PITKANEN, J.; IVERSEN, B.V.; DOUGLAS, J.T.; PAZ, A. Predicting depression storage from soil surface roughness. **Soil Sci. Soc. Am. J.**, v. 64, p. 1749-1758, 2000.

KÖPPEN, W. **Climatologia com un estudio de los climas de la tierra**. México: Fondo de Cultura Económica, 1948. 478 p.

KRISHNAN, P. Reflectance technique for predicting soil organic matter. **Soil Science Society of America Journal**, Madison, v. 44, p. 1282-1285, 1980.

KUIPERS, H. A relief meter for soil cultivation studies. **Neth. J. Agric. Sci.**, v. 5, p. 255-262, 1957.

LANDIS, J.; KOCH, G.G. The measurements of agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159-179, Mar. 1977.

LEHRSCHE, G.A.; WHISLER, F.D.; RÖMKENS, M.J.M. Soil surface roughness as influenced by selected soil physical properties. **Soil and Tillage Research**, v. 10, p. 197-212, 1987.

LEVIEN, R.; COGO, N.P.; ROCKENBACH, C.A. Erosão na cultura do milho em diferentes sistemas de cultivo anterior e métodos de preparo do solo. **R. Bras. Ci. Solo**, v. 14, p. 73-80, 1990.

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.

MACIEL, P. **Interpretação integrada de imagens de satélite e dados gamaespectrométricos da porção emersa da bacia de campos – Brasil**. Macaé: UENF, 2005.

MAETA, S.M. **Desenvolvimento da infra-estrutura embarcada do Projeto AURORA**. 2001. Dissertação (Mestrado) – Universidade Estadual de Campinas, Campinas, SP.

MARCEAU, D.J.; HOWARTH, P.J.; DUBOIS, J.M.M.; 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**, p. 513-519, 1990.

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

MELLO, R.C. Alterações físicas em um Latossolo Roxo em função da velocidade de aração e do ângulo horizontal dos discos. **Acta Scientiarum. Agronomy**, Maringá, v. 26, n. 1, p. 35-40, 2004.

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.

NERIS, L.O. **Um piloto automático para as aeronaves do Projeto ARARA**. 2001. Dissertação (Mestrado) – Instituto de Ciências Matemática e de Computação, USP, São Carlos, SP.

NOVO, E.M.L.M.; PONZONI, F.J. **Introdução ao sensoriamento remoto**. São José dos Campos, 2001.

OLIVEIRA, A.D. **Arado de discos: desempenho em função do ângulo do apo e das condições de superfície de um solo Podzólico Vermelho-amarelo Câmbico fase Terraço**. 1997. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG.

ONSTAD, C.A. Depressional storage on tilled soil surfaces. **Trans. Am. Soc. Agric. Eng.**, v. 27, p. 729-732, 1984.

ORLANDO, R.C. **Sistema de visão artificial para discriminação entre plantas daninhas e milho**. 2003. Tese (Doutorado) – Universidade Federal de Viçosa, Viçosa, MG.

PAZ GONZÁLEZ, A.; TABOADA CASTRO, M.T. Medida del microrrelieve del suelo y estimación de la retención hídrica en depresiones de la superficie. **Cadernos do Laboratorio Xeolóxico de Laxe**, v. 21, p. 829-842, 1996.

POMPERMAYER NETO, P. **Utilização da videografia aérea na detecção de áreas com deficiências nutricionais em plantios de eucalipto**. 2002. Dissertação (Mestrado) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, São Paulo, SP.

PONTI JÚNIOR, M.P. **Combinação de múltiplos classificadores para identificação de materiais em imagens ruidosas**. 2004. Dissertação (Mestrado) – Universidade Federal de São Carlos, São Carlos, SP.

RENNÓ, C.D. **Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens SIR-C/X-SAR do perímetro irrigado de Bebedouro, Petrolina, PE**. 2003. Dissertação (Mestrado) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP.

RICHARDS, J.A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 3.ed. Berlin: Springer-Verlag, 1999.

RODRIGUEZ YI, J.L. **Mapeamento e monitoramento da vegetação do Estado do Mato Grosso através de imagens AVHRR-NOAA**. 1998. 135 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP.

ROSENFELD, G.H.; FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 52, n. 2, p. 223-227, 1986.

RUY, S.R.; TOMMASELLI, A.M.G.; REIS, T.T.; GALO, M.; HASEGAWA, J.K.; IMAI, N.N.; CAMARGO, P.O. Sistema aerotransportado leve de aquisição de imagens digitais – SAAPI. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. **Anais...** Florianópolis: INPE, 2007. p. 1329-1335.

SAMA, M.P.; STOMBAUGH, T.S. Low cost remote sensing platform. In: SIMPÓSIO INTERNACIONAL DE AGRICULTURA DE PRECISÃO, 4, 2007, Viçosa. **CD-ROM...** Viçosa: UFV, 2007.

SANTOS, J.E.G. **Equipamento conjugado de preparo do solo**: desempenho em função da posição das hastes escarificadoras, do tipo de ponteira e da rotação do rotor. 1993. Tese (Doutorado em Energia na Agricultura) – Universidade do Estado de São Paulo, Botucatu, SP.

SANTOS, C. **Estatística descritiva**: manual de auto-aprendizagem. Lisboa: Edições Silabo, 2007.

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: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia. **Anais...** Goiânia: INPE, 2005. p. 2749-2757.

SARTORI, L.R.; IMAI, N.N.; TOMMASELLI, A.M.G.; SILVA, R.; GALO, R.M.; HASEGAWA, J.K.; CAMARGO, P.O. Potencial do uso da banda do infravermelho próximo na classificação de imagens adquiridas por câmaras digitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. **Anais...** Florianópolis: INPE, 2007. p. 6151-6158.

SCHMIDT, M.J. **Understanding and using statistics basic concepts**. Massachusetts, USA: D.C. Heath and Company, 1975.

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

SECCO, D.; REINERT, D.J. Efeitos imediato e residual de escarificadores em Latossolo Vermelho-Escuro sob plantio direto. **Eng. Agric.**, v. 16, p. 52-61, 1997.

SHABAN, M.A.; DIKSHIT, O. Textural classification of high resolution digital satellite imagery. **IEEE Transactions on Computers**, p. 2590-2592, 1998.

SILVA, E.A. **Introdução ao sensoriamento remoto**. Presidente Prudente: Universidade Estadual Paulista, 2002. 77 p.

SILVA, R.D. **Segmentação de imagens baseada em descritores de textura extraídos por transformadas Wavelets**. 2008. Dissertação (Mestrado) – Universidade Federal do Paraná, Curitiba, PR.

SILVA, R.P.; CORÁ, J.E.; LOPES, A.; FURLANI, C.E.A. Ação de rodas compactadoras de semeadoras submetidas a cargas verticais na deformação do solo. **Ciência e Agrotecnologia**, Lavras, v. 29, n. 4, p. 839-847, 2005.

SILVA JÚNIOR, M.C. **Detecção do efeito da adubação nitrogenada em *Brachiaria decumbens* utilizando técnicas de sensoriamento remoto.** 2006. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG.

SILVEIRA, P.M.; ZIMMERMANN, F.J.P.; SILVA, S.C.; CUNHA, A.A. Amostragem e variabilidade espacial de características químicas de um latossolo submetido a diferentes sistemas de preparo. **Pesquisa Agropecuária Brasileira**, Brasília, v. 35, 2000.

STEFFEN, C.A. **Introdução ao sensoriamento remoto.** São José dos Campos: INPE, 2006.

SWAIN, P.H. Fundamentals of pattern recognition in remote sensing. In: SWAIN, P.H.; DAVIS, S.H. **Remote sensing: a quantitative approach.** New York: McGraw-Hill, 1978. cap. 3, p. 136-187.

SZAKÁCS, G.G.J. **Seqüestro de carbonos nos solos:** avaliação das potencialidades dos solos arenosos sob pastagens. 2003. Dissertação (Mestrado em Energia Nuclear na Agricultura) – Centro de Energia Nuclear na Agricultura, Piracicaba, SP.

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. In: ANNUAL INTERNATIONAL MEETING, 1999, Toronto, Ontario. **Proceedings...** Toronto, Ontário, 1999. 10 p.

ULABY, F.T.; KOUYATE, F.; BRISCO, B.; LEE WILLIAMS, T.H. Textural information in SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 24, n. 2, p. 235-245, Mar. 1986.

VANNI, S.M. **Modelos de regressão:** estatística aplicada. São Paulo: Legmar Informática, 1998. 177 p.

VÁZQUEZ, E.V.; DE MARIA, I.C. Influencia del Laboreo sobre la rugosidad del suelo y la retención de agua en un Ferrasol. In: CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO, 29, 2003, Ribeirão Preto. **Resumo expandido...** Ribeirão Preto: Sociedade Brasileira de Ciência do Solo, 2003.

VETTORAZZI, C.A.; COUTO, H.T.Z.; FERRAZ, S.F.B.; POMPERMAYER, P. Videografia aérea como fonte de dados para a tomada de decisões em agricultura. In: SIMPÓSIO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2000, Piracicaba. **Anais...** Piracicaba: ESALQ, 2000. p. 197-200.

VOLK, L.B.S.; COGO, N.P.; STRECK, E.V. Erosão hídrica influenciada por condições físicas de superfície e subsuperfície do solo resultantes do seu manejo, na ausência de cobertura vegetal. **R. Bras. Ci. Solo**, v. 28, p. 763-774, 2004.

WELLS, L.G.; STOMBAUGH, T.S.; SHEARER, S.A. **Application and assessment of precision deep tillage**. California: ASAE Sacramento Convention Center, 2001. (Paper, 1032).

APÊNDICES

APÊNDICE A

CÓDIGO FONTE PARA O CÁLCULO DO ÍNDICE DE RUGOSIDADE SUPERFICIAL DO SOLO

```
% ROTINA PARA CALCULO DE RUGOSIDADE
clear;clc;
cd ('C:\Documents and
Settings\Leonardo\Meusdocumentos\Doutorado\Projeto\experimento\bloco3\p1')%
Diretório da imagem (modificar)
disp ''
disp ' ROTINA PARA CALCULO DO INDICE DE RUGOSIDADE'
disp ''
a=imread(uigetfile('* .jpg')); % Nome da imagem (modificar)
b=imcrop(a);

[CV,LV,P]=impixel(b);

D1=LV(4,1)-LV(1,1); D2=LV(3,1)-LV(2,1); D3=CV(2,1)-CV(1,1); D4=CV(3,1)-CV(4,1);

TanALFA=((abs(LV(3,1)-LV(4,1)))/D4);
ALFA=rad2deg(TanALFA);

[CH,LH,P] = impixel(b);

Angulo_Rad=(90-ALFA)*(pi/180);
A=sin(Angulo_Rad);

N=20; % Numero de hastes (modificar)
for i=1:N % Numeros de hastes
    if LV(3,1)<LV(4,1)
        X2=(LV(4,1)-LH(i,1));
        X1=(CH(i,1)-CV(4,1));
    else
```

```

        X2=(LV(3,1)-LH(i,1));
        X1=(CV(3,1)-CH(i,1));
    end
    Y=X1*TanALFA;
    X3=X2-Y;
    h=X3*A;
    HP(i,1)=h;
end

DM=(D1+D2)/2;
Hcm=((HP.*20)/DM)+5
IR=sqrt((sum((Hcm-mean(Hcm)).^2))/N)
FINAL=[Hcm;0;IR]
wk1write ('B1P5',FINAL)%trocar o nome toda vez que trocar de imagem
%B=bloco, %P=parcela, %numero da leitura de 1 a 10

```

APÊNDICE B

CÓDIGO FONTE PARA RECORTE DOS BLOCOS DAS IMAGENS

```
clear; clc;
dir_grava='C:\DocumentsandSettings\Luciano\Desktop\LEONARDO\balãoecor\bloco1
\p5\50m\iv\50_50\';

d=dir;
str={d.name};

for i=3:size(str,2) % Verificar em qual posição começa as imagens (dir)
    a=str(i);
    a=a{1,1};
    ima=imread(a);
    imshow(ima);
    [col lin r]=impixel(ima);
    local=strcat(dir_grava,a,'.txt');
    fid=fopen(local,'w');
    arq=[col lin];

    fprintf(fid,'%4.0f %4.0f\n',arq);

    fclose(fid);
end
n=50
for k=1:1% numero de amostras

    fad='R1'; %para ler (R1-> BLOCO 1, parcela1, R2, parcela2...)(L-> BLOCO 2, L1
parcela1, L2 parcela2,...)
    %(P->BLOCO 3, P1 parcela1, P2 parcela2,...)VERIFICAR O NUMERO DE
    %IMAGENS EM CADA PARCELA E O NUMERO DEPOIS DA LETRA EX:R22,
dir_grava='C:\DocumentsandSettings\Luciano\Desktop\LEONARDO\balãoecor\bloco1
\p5\50m\iv\50_50\'; %imagens
```

```

dir_le='C:\Documents and
Settings\Luciano\Desktop\LEONARDO\balãorecor\bloco1\p5\50m\iv\50_50\';% arquivo
txt
dir_lee='C:\Documents and
Settings\Luciano\Desktop\LEONARDO\balãorecor\bloco1\New Folder\';% imagens
    arq=strcat(dir_le,fad,num2str(k),'.jpg.txt');
    [col,lin]=textread(arq,'%d%d');
    for i=1:50% numero de recortes de cada amostra
        ext='.jpg';
        n=n+1;
        ima=strcat(fad,num2str(k),ext);
        local=strcat(dir_lee,ima);
        im=imread(local);
        coli=col(i);
        lini=lin(i);
        amostra=im(lini:lini+49,coli:coli+49,:);%tamanho do bloco
        nome=strcat(dir_grava,'bloco',num2str(n),'.jpg');
        imwrite(amostra,nome);
    end
end

fim='FIM DO PROCESSAMENTO'

```

APÊNDICE C

CÓDIGO FONTE PARA A MONTAGEM DA MATRIZ DE CO-OCORRÊNCIA E CÁLCULO DOS DESCRITORES TEXTURAIS

```
%% O algoritmo gera os parâmetros texturais nas direções 0° 45° 90° e 135°.
% Modificado de ROBERTO CARLOS ORLANDO & HENRIQUE ANASTÁCIO ALVES
% marco de 2003
-
% arquivo: classificador.m
clear;
clc
clear

for n=1:100
    n
    AA=imread(strcat('C:\Documents and Settings\Usuario\Meus
documentos\Doutorado\Projeto\experimento\pesquisa\balãorecor\bloco3\p1\4m\iv\50_
50\bloco',num2str(n),'.JPG'));
    A=(AA(:,:,3));
    %A=rgb2gray(AA);
    %A=imadjust(A1,[],[],0.5);

    %transformar a imagem em tons de cinza
    %montagem da matriz de co-ocorrência, de onde serão extraídos os
    %descritores texturais de cada classe(momento angular, média, variância, entropia,
    correlação, momento do produto, momento inverso da diferença e medidas de
    correlação)

    ngl=255; % numero de níveis de cinza
    n_linhas = size(A,1); % numero de linhas
    n_colunas = size(A,2); %numero de colunas
    P=zeros(ngl); % zera a matriz de co-ocorrência
```

```

P_45=zeros(ngl);
P_90=zeros(ngl);
P_135=zeros(ngl);

% Matriz P para teta igual a zero
for i=1:n_linhas
    for j=1:n_colunas
        if (j==1)
            P(A(i,1)+1,A(i,2)+1)=P(A(i,1)+1,A(i,2)+1)+1;
        else
            if (j==n_colunas)
                P(A(i,n_colunas)+1,A(i,n_colunas-
1)+1)=P(A(i,n_colunas)+1,A(i,n_colunas-1)+1)+1;
            else
                P(A(i,j)+1,A(i,j+1)+1)=P(A(i,j)+1,A(i,j+1)+1)+1;
                P(A(i,j)+1,A(i,j-1)+1)=P(A(i,j)+1,A(i,j-1)+1)+1;
            end
        end
    end
end

%Matriz P para teta igual a 45
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            if (j~=1)
                P_45(A(i,j)+1,A(i+1,j-1)+1)=P_45(A(i,j)+1,A(i+1,j-1)+1)+1;
            end
        else
            if (i==n_linhas)
                if (j~=n_colunas)
                    P_45(A(i,j)+1,A(i-1,j+1)+1)=P_45(A(i,j)+1,A(i-1,j+1)+1)+1;
                end
            else if (j==1)
                P_45(A(i,j)+1,A(i-1,j+1)+1)=P_45(A(i,j)+1,A(i-1,j+1)+1)+1;
            else if (j==n_colunas)
                P_45(A(i,j)+1,A(i+1,j-1)+1)=P_45(A(i,j)+1,A(i+1,j-1)+1)+1;
            else
                P_45(A(i,j)+1,A(i+1,j-1)+1)=P_45(A(i,j)+1,A(i+1,j-1)+1)+1;
                P_45(A(i,j)+1,A(i-1,j+1)+1)=P_45(A(i,j)+1,A(i-1,j+1)+1)+1;
            end
        end
    end
end

% matriz P para teta igual a 90
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            P_90(A(1,j)+1,A(2,j)+1)=P_90(A(1,j)+1,A(2,j)+1)+1;
        else if (i==n_linhas)
            P_90(A(n_linhas,j)+1,A(n_linhas-1,j)+1)=P_90(A(n_linhas,j)+1,A(n_linhas-
1,j)+1)+1;

```

```

else
    P_90(A(i,j)+1,A(i+1,j)+1)=P_90(A(i,j)+1,A(i+1,j)+1)+1;
    P_90(A(i,j)+1,A(i-1,j)+1)=P_90(A(i,j)+1,A(i-1,j)+1)+1;
end
end
end
end

% matriz P para teta igual a 135
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            if (j~=n_colunas);
                P_135(A(i,j)+1,A(i+1,j+1)+1)=P_135(A(i,j)+1,A(i+1,j+1)+1)+1;
            end
        else if (i==n_linhas);
            if (j~=1);
                P_135(A(i,j)+1,A(i-1,j-1)+1)=P_135(A(i,j)+1,A(i-1,j-1)+1)+1;
            end
        else if (j==1);
            P_135(A(i,j)+1,A(i+1,j+1)+1)=P_135(A(i,j)+1,A(i+1,j+1)+1)+1;
        else if (j==n_colunas);
            P_135(A(i,j)+1,A(i-1,j-1)+1)=P_135(A(i,j)+1,A(i-1,j-1)+1)+1;
        else
            P_135(A(i,j)+1,A(i+1,j+1)+1)=P_135(A(i,j)+1,A(i+1,j+1)+1)+1;
            P_135(A(i,j)+1,A(i-1,j-1)+1)=P_135(A(i,j)+1,A(i-1,j-1)+1)+1;
        end
    end
end
end
end
end
end
end

```

%normalização da matriz de co-ocorrência

```

p = P./sum(sum(P));
p_45 = P_45./sum(sum(P_45));
p_90 = P_90./sum(sum(P_90));
p_135 = P_135./sum(sum(P_135));

```

% probabilidade marginal da matriz

```

px=sum(p);
px_45=sum(p_45);
px_90=sum(p_90);
px_135=sum(p_135);

```

% momento angular

```

f1=sum(sum(p.^2));
f1_45=sum(sum(p_45.^2));
f1_90=sum(sum(p_90.^2));
f1_135=sum(sum(p_135.^2));

```

% valor medio

```

f2=0;

```

```

f2_45=0;
f2_90=0;
f2_135=0;
for i=1:ngl-1
    f2=(i*px(i+1))+f2;
    f2_45=(i*px_45(i+1))+f2_45;
    f2_90=(i*px_90(i+1))+f2_90;
    f2_135=(i*px_135(i+1))+f2_135;
end

% variância
f3=0;
f3_45=0;
f3_90=0;
f3_135=0;
for i=0:ngl-1
    f3=((i-f2)^2)*px(i+1))+f3;
    f3_45=((i-f2_45)^2)*px_45(i+1))+f3_45;
    f3_90=((i-f2_90)^2)*px_90(i+1))+f3_90;
    f3_135=((i-f2_135)^2)*px_135(i+1))+f3_135;
end

% correlação
f4=0;
f4_45=0;
f4_90=0;
f4_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        f41=i*j*p(i+1,j+1))+f4;
        f41_45=i*j*p_45(i+1,j+1))+f4_45;
        f41_90=i*j*p_90(i+1,j+1))+f4_90;
        f41_135=i*j*p_135(i+1,j+1))+f4_135;
    end
end
if f3==0
    f3=0.00001;
end
if f3_45==0
    f3_45=0.00001;
end
if f3_90==0
    f3_90=0.00001;
end
if f3_135==0
    f3_135=0.00001;
end
f4=(f41-f2^2)/f3;
f4_45=(f41_45-f2_45^2)/f3_45;
f4_90=(f41_90-f2_90^2)/f3_90;
f4_135=(f41_135-f2_135^2)/f3_135;

% momento do produto
f5=0;
f5_45=0;

```

```

f5_90=0;
f5_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        f5=(((i-f2)*(j-f2))*p(i+1,j+1))+f5;
        f5_45=(((i-f2_45)*(j-f2_45))*p_45(i+1,j+1))+f5_45;
        f5_90=(((i-f2_90)*(j-f2_90))*p_90(i+1,j+1))+f5_90;
        f5_135=(((i-f2_135)*(j-f2_135))*p_135(i+1,j+1))+f5_135;
    end
end

```

% Diferença inversa do momento

```

f6=0;
f6_45=0;
f6_90=0;
f6_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        f6=(p(i+1,j+1)/(1+(i-j)^2))+f6;
        f6_45=(p_45(i+1,j+1)/(1+(i-j)^2))+f6_45;
        f6_90=(p_90(i+1,j+1)/(1+(i-j)^2))+f6_90;
        f6_135=(p_135(i+1,j+1)/(1+(i-j)^2))+f6_135;
    end
end

```

% entropia

```

f7=0;
f7_45=0;
f7_90=0;
f7_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        if p(i+1,j+1)==0
            p(i+1,j+1)=0.000001;
        end
        f7=p(i+1,j+1)*log(p(i+1,j+1))+f7;
        if p_45(i+1,j+1)==0
            p_45(i+1,j+1)=0.000001;
        end
        f7_45=p_45(i+1,j+1)*log(p_45(i+1,j+1))+f7_45;
        if p_90(i+1,j+1)==0
            p_90(i+1,j+1)=0.000001;
        end
        f7_90=p_90(i+1,j+1)*log(p_90(i+1,j+1))+f7_90;
        if p_135(i+1,j+1)==0
            p_135(i+1,j+1)=0.000001;
        end
        f7_135=p_135(i+1,j+1)*log(p_135(i+1,j+1))+f7_135;
    end
end

```

% medidas de correlação

```

hx=0;
hx_45=0;
hx_90=0;

```

```

hx_135=0;
for i=1:ngl
    if px(i)==0
        px(i)=0.00001;
    end
    hx=-px(i)*log(px(i))+hx;
    if px_45(i)==0
        px_45(i)=0.00001;
    end
    hx_45=-px_45(i)*log(px_45(i))+hx_45;
    if px_90(i)==0
        px_90(i)=0.00001;
    end
    hx_90=-px_90(i)*log(px_90(i))+hx_90;
    if px_135(i)==0
        px_135(i)=0.00001;
    end
    hx_135=-px_135(i)*log(px_135(i))+hx_135;
end
hxy1=0;
hxy1_45=0;
hxy1_90=0;
hxy1_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        pcx1=px(i+1)*px(j+1);
        pcx1_45=(px_45(i+1)*px_45(j+1));
        pcx1_90=(px_90(i+1)*px_90(j+1));
        pcx1_135=(px_135(i+1)*px_135(j+1));
        if pcx1==0
            pcx1=0.00001;
        end
        hxy1=-(p(i+1,j+1)*log(pcx1))+hxy1;
        if pcx1_45==0
            pcx1_45=0.00001;
        end
        hxy1_45=-(p_45(i+1,j+1)*log(pcx1_45))+hxy1_45;
        if pcx1_90==0
            pcx1_90=0.00001;
        end
        hxy1_90=-(p_90(i+1,j+1)*log(pcx1_90))+hxy1_90;
        if pcx1_135==0
            pcx1_135=0.00001;
        end
        hxy1_135=-(p_135(i+1,j+1)*log(pcx1_135))+hxy1_135;
    end
end
hxy2=0;
hxy2_45=0;
hxy2_90=0;
hxy2_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        pcx2=px(i+1)*px(j+1);
        pcx2_45=(px_45(i+1)*px_45(j+1));

```

```

pcx2_90=(px_90(i+1)*px_90(j+1));
pcx2_135=(px_135(i+1)*px_135(j+1));
if pcx2==0
    pcx2=0.00001;
end
hxy2= -(px(i+1)*px(j+1))*log(pcx2)+hxy2;
if pcx2_45==0
    pcx2_45=0.00001;
end
hxy2_45= -(px_45(i+1)*px_45(j+1))*log(pcx2_45)+hxy2_45;
if pcx2_90==0
    pcx2_90=0.00001;
end
hxy2_90= -(px_90(i+1)*px_90(j+1))*log(pcx2_90)+hxy2_90;
if pcx2_135==0
    pcx2_135=0.00001;
end
hxy2_135= -(px_135(i+1)*px_135(j+1))*log(pcx2_135)+hxy2_135;
end
end
f10=0;
f10_45=0;
f10_90=0;
f10_135=0;
f10=(f7-hxy1)/hx;
f10_45=(f7_45-hxy1_45)/hx_45;
f10_90=(f7_90-hxy1_90)/hx_90;
f10_135=(f7_135-hxy1_135)/hx_135;

```

% salva o resultado da imagem

```

F_0=[f1;f2;f3;f4;f5;f6;f7;f10]
F_45=[f1_45;f2_45;f3_45;f4_45;f5_45;f6_45;f7_45;f10_45]
F_90=[f1_90;f2_90;f3_90;f4_90;f5_90;f6_90;f7_90;f10_90]
F_135=[f1_135;f2_135;f3_135;f4_135;f5_135;f6_135;f7_135;f10_135]

```

```

File_0=fopen('0_50_B_B3_20vis.xls','a');
fprintf(File_0,'\t %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft
%10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n
%10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft
%10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft\n',F_0);
fclose(File_0);

```

```

File_45=fopen('45_50_B_B3_20vis.xls','a');
fprintf(File_45,'\t %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft
%10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n
%10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft
%10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft\n',F_45);
fclose(File_45);

```

```

File_90=fopen('90_50_B_B3_20vis.xls','a');
fprintf(File_90,'\t %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft
%10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n

```

```
%10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft
%10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft\n',F_90);
fclose(File_90);

File_135=fopen('135_50_B_B3_20vis.xls','a');
fprintf(File_135,'\t %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft %10.4ft
%10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n
%10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft \n %10.4ft
%10.4ft %10.4ft %10.4ft \n %10.4ft %10.4ft %10.4ft %10.4ft\n',F_135);
fclose(File_135);
end
```

APÊNDICE D

Tabela 1D – Exemplo de uma matriz com os valores dos descritores texturais

N.º de amostras	Classes	Descritores texturais							
		1	2	3	4	5	6	7	8
1	1	0.0052	225.5	49.8786	-1019.48	45.8276	0.3883	-6.5219	-4.3269
2	1	0.0056	225.6198	51.165	-994.904	47.1334	0.3862	-6.4954	-4.3279
3	1	0.0066	226.9586	31.3785	-1641.58	28.086	0.4012	-6.2435	-4.4052
4	1	0.0067	227.5541	29.6793	-1744.68	26.482	0.4075	-6.2181	-4.4151
5	1	0.0058	227.5765	39.0792	-1325.28	35.5546	0.4104	-6.3722	-4.3658
...
98	1	0.0054	225.7751	46.2462	-1102.24	41.9543	0.3693	-6.5345	-4.3494
99	1	0.0053	226.1816	44.4629	-1150.58	39.9001	0.3685	-6.5478	-4.3646
100	1	0.0056	226.1573	37.4799	-1364.65	33.3818	0.367	-6.4374	-4.3901
1	2	0.0035	215.3488	64.3202	-721.004	56.9877	0.3054	-6.9203	-4.341
2	2	0.003	214.8947	71.6673	-644.363	64.1603	0.2835	-7.0138	-4.3262
3	2	0.0036	214.4896	62.9858	-730.415	55.515	0.3192	-6.87	-4.3327
4	2	0.0032	214.7941	72.7496	-634.182	64.898	0.3017	-6.9839	-4.3166
5	2	0.0033	214.7492	65.2381	-706.906	58.1534	0.2976	-6.923	-4.3337
...
98	2	0.004	217.5251	51.8502	-912.575	45.7235	0.3267	-6.7731	-4.3637
99	2	0.0033	217.6488	57.4368	-824.749	50.2003	0.2964	-6.9113	-4.37
100	2	0.0038	219.0757	58.4594	-820.983	51.7869	0.3117	-6.8452	-4.3467
1	3	0.0029	233.6559	83.2898	-653.903	75.0567	0.2845	-7.0709	-4.3082
2	3	0.0036	235.6861	73.9933	-734.701	67.2317	0.3288	-6.9122	-4.3133
3	3	0.0034	232.3604	68.0126	-791.908	60.4109	0.3006	-6.9334	-4.3389
4	3	0.0041	234.0641	54.8632	-997.632	48.8526	0.3359	-6.7481	-4.3563
5	3	0.0052	239.0118	41.8741	-1362.99	36.6913	0.342	-6.5368	-4.4007
...
98	3	0.0041	232.8657	47.1701	-1149.59	39.7252	0.301	-6.7728	-4.4134
99	3	0.004	236.4202	48.8171	-1144.44	42.2667	0.3204	-6.7368	-4.3896
100	3	0.0052	238.2757	42.0393	-1348.65	36.8832	0.3656	-6.5541	-4.3982
1	4	0.0023	225.9616	157.41	-324.367	146.2802	0.2583	-7.3427	-4.2364
2	4	0.0019	223.2273	161.603	-308.351	145.7916	0.2251	-7.5141	-4.2565
3	4	0.0033	231.4037	89.4428	-598.092	80.5158	0.3203	-7.0305	-4.2896
4	4	0.0045	234.3131	77.1387	-710.373	68.6665	0.345	-6.8027	-4.3267
5	4	0.0028	232.83	103.9382	-521.558	92.656	0.2708	-7.176	-4.3051
...

Continua...

Tabela 1D, Cont.

N.º de amostras	Classes	Descritores texturais							
		1	2	3	4	5	6	7	8
98	4	0.002	223.7445	250.8061	-198.238	233.44	0.242	-7.5828	-4.1822
99	4	0.0016	224.3788	245.0002	-204.526	224.4614	0.2118	-7.6969	-4.1967
100	4	0.0014	223.0039	212.5581	-233.715	188.3563	0.1915	-7.7799	-4.2218
1	5	0.0058	230.5916	568.5824	-85.9222	529.9687	0.2346	-7.6781	-4.1414
2	5	0.0088	235.2429	317.3427	-157.04	290.9186	0.2792	-7.3727	-4.2002
3	5	0.0033	230.3359	355.1153	-140.874	321.5263	0.2121	-7.8259	-4.1899
4	5	0.0055	235.1455	271.6219	-188.735	249.0947	0.2486	-7.4946	-4.2212
5	5	0.0038	234.5427	275.1119	-188.948	253.7165	0.2243	-7.5461	-4.2137
...
98	5	0.0022	217.7633	629.6382	-71.2158	576.5542	0.1684	-8.3179	-4.1157
99	5	0.0049	226.3994	485.704	-97.1814	444.047	0.2101	-7.9515	-4.1533
100	5	0.0055	233.3988	310.2908	-161.898	277.3483	0.2034	-7.6651	-4.2231

APÊNDICE E

CÓDIGO FONTE DO ALGORITMO DE CLASSIFICAÇÃO

```
% algoritmo para elaboração e avaliação de classificador estatístico
% validação cruzada
% 5 classes de rugosidade do solo
% Modificado de Darly Geraldo de Sena Jr., novembro 2004.
%%
%% TROCAR NOME DO ARQUIVO A SER SALVO NO FINAL
%%
clear
clc
% carrega os dados
[nomearq,caminho] = uigetfile('*.xls','Selecione dados de origem');
dados=xlsread(strcat(caminho,nomearq));
parc=dados(:,1);
mat=dados(:,2:size(dados,2));
% calcula as combinacoes
indices=size(mat,2);
v=[1:indices];
% inicializa a matriz resultados do kappa
res_kappa=zeros(1,size(v,2)+2);
% inicializa o contador de combinacoes
tot_comb=5;
tic
for n=1:indices;
    comb=combnk(v,n);
    disp(n)
    % monta a matriz com a combinacao da vez
    for i=1:size(comb,1)
        comb_vez=comb(i,:);
        tot_comb=tot_comb+1;
        for k=1:size(comb_vez,2)
```

```

    p=comb_vez(k);
    mat_vez(:,k)=mat(:,p);
end
% classificador
% *****
contin=zeros(5,5);
% calcula dados para elaboracao do classificador
% inicializa contador das classes
% monta a matriz de cada classe para leave-one-out(loo)
for nc=1:size(mat_vez,1)
    conta_1=1;
    conta_2=1;
    conta_3=1;
    conta_4=1;
    conta_5=1;
    for c=1:size(mat_vez,1)
        if c ~= nc
            if parc(c,1)==1;
                mat_1(conta_1,:)=mat_vez(c,:);
                conta_1=conta_1+1;
            elseif parc(c,1)==2;
                mat_2(conta_2,:)=mat_vez(c,:);
                conta_2=conta_2+1;
            elseif parc(c,1)==3;
                mat_3(conta_3,:)=mat_vez(c,:);
                conta_3=conta_3+1;
            elseif parc(c,1)==4;
                mat_4(conta_4,:)=mat_vez(c,:);
                conta_4=conta_4+1;
            elseif parc(c,1)==5;
                mat_5(conta_5,:)=mat_vez(c,:);
                conta_5=conta_5+1;
            end
        end
    end
end % c=1:size(mat_vez,1)
% calcula media e matriz de covariancia
med_1=mean(mat_1);
med_2=mean(mat_2);
med_3=mean(mat_3);
med_4=mean(mat_4);
med_5=mean(mat_5);
cov_1=cov(mat_1);
cov_2=cov(mat_2);
cov_3=cov(mat_3);
cov_4=cov(mat_4);
cov_5=cov(mat_5);
% calcula os "d's"
d1=-0.5*(mat_vez(nc,:)-med_1)*inv(cov_1)*(mat_vez(nc,:)-med_1)-
0.5*log(det(cov_1));
d2=-0.5*(mat_vez(nc,:)-med_2)*inv(cov_2)*(mat_vez(nc,:)-med_2)-
0.5*log(det(cov_2));
d3=-0.5*(mat_vez(nc,:)-med_3)*inv(cov_3)*(mat_vez(nc,:)-med_3)-
0.5*log(det(cov_3));
d4=-0.5*(mat_vez(nc,:)-med_4)*inv(cov_4)*(mat_vez(nc,:)-med_4)-
0.5*log(det(cov_4));

```

```

d5=-0.5*(mat_vez(nc,:)-med_5')*inv(cov_5)*(mat_vez(nc,:)-med_5')-
0.5*log(det(cov_5));
% "escolhe" o maior "d"
[dmax,classe]=max([d1;d2;d3;d4;d5]);
% monta a matriz de erros
if parc(nc,1)==1 & classe==1
    contin(1,1)=contin(1,1)+1;
elseif parc(nc,1)==1 & classe==2
    contin(1,2)=contin(1,2)+1;
elseif parc(nc,1)==1 & classe==3
    contin(1,3)=contin(1,3)+1;
elseif parc(nc,1)==1 & classe==4
    contin(1,4)=contin(1,4)+1;
elseif parc(nc,1)==1 & classe==5
    contin(1,5)=contin(1,5)+1;
%
elseif parc(nc,1)==2 & classe==1
    contin(2,1)=contin(2,1)+1;
elseif parc(nc,1)==2 & classe==2
    contin(2,2)=contin(2,2)+1;
elseif parc(nc,1)==2 & classe==3
    contin(2,3)=contin(2,3)+1;
elseif parc(nc,1)==2 & classe==4
    contin(2,4)=contin(2,4)+1;
elseif parc(nc,1)==2 & classe==5
    contin(2,5)=contin(2,5)+1;
%
elseif parc(nc,1)==3 & classe==1
    contin(3,1)=contin(3,1)+1;
elseif parc(nc,1)==3 & classe==2
    contin(3,2)=contin(3,2)+1;
elseif parc(nc,1)==3 & classe==3
    contin(3,3)=contin(3,3)+1;
elseif parc(nc,1)==3 & classe==4
    contin(3,4)=contin(3,4)+1;
elseif parc(nc,1)==3 & classe==5
    contin(3,5)=contin(3,5)+1;
%
elseif parc(nc,1)==4 & classe==1
    contin(4,1)=contin(4,1)+1;
elseif parc(nc,1)==4 & classe==2
    contin(4,2)=contin(4,2)+1;
elseif parc(nc,1)==4 & classe==3
    contin(4,3)=contin(4,3)+1;
elseif parc(nc,1)==4 & classe==4
    contin(4,4)=contin(4,4)+1;
elseif parc(nc,1)==4 & classe==5
    contin(4,5)=contin(4,5)+1;
%
elseif parc(nc,1)==5 & classe==1
    contin(5,1)=contin(5,1)+1;
elseif parc(nc,1)==5 & classe==2
    contin(5,2)=contin(5,2)+1;
elseif parc(nc,1)==5 & classe==3
    contin(5,3)=contin(5,3)+1;

```

```

elseif parc(nc,1)==5 & classe==4
    contin(5,4)=contin(5,4)+1;
elseif parc(nc,1)==5 & classe==5
    contin(5,5)=contin(5,5)+1;
    %
end
% limpa as matrizes da validacao cruzada
clear mat_1 mat_2 mat_3 mat_4 mat_5
% *****
end % nc=1:size(mat_vez,1)
[kappa,var_kappa]=kappa_rot(contin);
% armazena kappa e var_kappa
res_kappa(tot_comb,1:size(comb_vez,2))=comb_vez;
res_kappa(tot_comb,10)=trace(contin)/sum(sum(contin));
res_kappa(tot_comb,11)=kappa;
res_kappa(tot_comb,12)=var_kappa;
res_kappa(tot_comb,13:17)=contin(1,1:5);
res_kappa(tot_comb,18:22)=contin(2,1:5);
res_kappa(tot_comb,23:27)=contin(3,1:5);
res_kappa(tot_comb,28:32)=contin(4,1:5);
res_kappa(tot_comb,33:37)=contin(5,1:5);
% *****
% passa para a proxima combinacao
clear mat_vez
end % i=1:size(comb,1)
end % n=1:indices;
toc
nome_salva=(strcat('test_135_50_R_B1_100iv_clas.xls'))
xlswrite(nome_salva,res_kappa);

```

APÊNDICE F

Tabela 1F – Exemplo de parte da planilha gerada pelo classificador, com as combinações dos descritores utilizados, exatidão global, índice kappa, variância do índice kappa e a matriz de classificação

**Descritores utilizados	E.G	Kappa	Variância	Matriz de classificação com as 5 classes																								
				1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	1	2	3	4	5
1000000000	0.46	0.32	0.00061	0	24	63	4	9	0	43	43	5	9	0	15	77	3	5	0	0	6	94	0	0	17	35	32	16
2000000000	0.532	0.41	0.00074	56	23	0	21	0	31	69	0	0	0	0	0	92	0	8	44	9	4	21	22	19	11	15	27	28
4000000000	0.572	0.46	0.00068	3	21	71	5	0	11	23	61	5	0	7	15	72	6	0	2	0	4	91	3	0	0	0	3	97
5000000000	0.564	0.45	0.00071	0	58	40	2	0	6	52	41	1	0	0	50	44	6	0	0	1	7	88	4	0	0	0	2	98
6000000000	0.424	0.28	0.00071	17	31	48	4	0	16	55	23	6	0	23	24	42	11	0	1	0	10	23	66	0	0	2	23	75
7000000000	0.51	0.38	0.00067	1	33	65	1	0	4	55	40	1	0	1	22	73	4	0	0	0	7	41	52	0	0	0	15	85
8000000000	0.552	0.44	0.00072	24	19	54	3	0	23	18	55	4	0	14	12	70	4	0	0	8	2	79	11	0	0	0	15	85
1300000000	0.63	0.53	0.00072	50	31	17	2	0	36	44	20	0	0	33	33	28	6	0	2	0	5	93	0	0	0	0	0	100
1400000000	0.628	0.53	0.00070	17	26	51	6	0	26	51	20	3	0	14	22	58	6	0	2	3	2	93	0	0	0	0	5	95
1600000000	0.608	0.51	0.00072	20	27	46	7	0	19	48	27	6	0	16	25	55	4	0	4	0	4	91	1	0	0	0	10	90
1800000000	0.646	0.55	0.00069	20	25	48	7	0	16	51	31	2	0	10	22	62	6	0	3	1	3	91	2	0	0	0	1	99
2300000000	0.866	0.83	0.00036	69	31	0	0	0	26	74	0	0	0	0	0	96	4	0	0	0	5	94	1	0	0	0	0	100
2400000000	0.868	0.83	0.00035	71	29	0	0	0	28	72	0	0	0	0	0	98	2	0	0	0	6	94	0	0	0	0	1	99
2450000000	0.896	0.87	0.00029	81	17	0	2	0	24	76	0	0	0	0	0	96	4	0	0	0	5	95	0	0	0	0	0	100
2460000000	0.928	0.91	0.00020	88	12	0	0	0	14	86	0	0	0	0	0	97	3	0	0	0	5	95	0	0	1	0	1	98
2680000000	0.936	0.92	0.00018	88	12	0	0	0	14	86	0	0	0	0	0	97	3	0	0	0	3	97	0	0	0	0	0	100
2780000000	0.94	0.92	0.00017	89	11	0	0	0	12	88	0	0	0	0	0	97	3	0	0	0	3	97	0	0	0	0	1	99
3780000000	0.672	0.59	0.00068	52	39	8	1	0	37	56	7	0	0	30	26	39	5	0	4	0	5	89	2	0	0	0	0	100
3680000000	0.672	0.59	0.00068	53	36	8	3	0	43	52	5	0	0	31	21	43	5	0	2	0	7	88	3	0	0	0	0	100
3670000000	0.638	0.54	0.00070	48	38	13	1	0	29	57	14	0	0	33	37	25	5	0	4	0	4	89	3	0	0	0	0	100
3580000000	0.652	0.56	0.00070	28	36	36	0	0	27	56	17	0	0	15	30	52	3	0	1	1	6	90	2	0	0	0	0	100
3570000000	0.654	0.56	0.00070	38	47	13	2	0	31	60	9	0	0	26	31	40	3	0	4	0	4	89	3	0	0	0	0	100
3480000000	0.738	0.67	0.00060	53	37	9	1	0	38	57	4	1	0	7	19	68	6	0	1	1	5	92	1	0	0	0	1	99
3470000000	0.732	0.66	0.00061	47	37	16	0	0	28	66	6	0	0	8	21	65	6	0	1	0	6	89	4	0	0	0	1	99
12356780	0.926	0.90	0.00021	88	12	0	0	0	15	85	0	0	0	0	0	96	4	0	0	0	6	94	0	0	0	0	0	100
12456780	0.924	0.90	0.00021	85	15	0	0	0	14	86	0	0	0	0	0	96	4	0	0	0	5	95	0	0	0	0	0	100
13456780	0.734	0.66	0.00061	57	34	8	1	0	35	60	5	0	0	21	17	57	5	0	3	1	3	93	0	0	0	0	0	100
23456780	0.932	0.91	0.00019	89	11	0	0	0	14	86	0	0	0	0	0	95	5	0	0	0	4	96	0	0	0	0	0	100
12345678	0.922	0.90	0.00022	86	14	0	0	0	15	85	0	0	0	0	0	96	4	0	0	0	6	94	0	0	0	0	0	100

**Esta é uma parte da tabela de classificação, cada tabela possui 255 linhas x 37 colunas, para cada classe o número de amostras utilizadas na classificação era igual a 100, E.G exatidão global (%).

APÊNDICE G

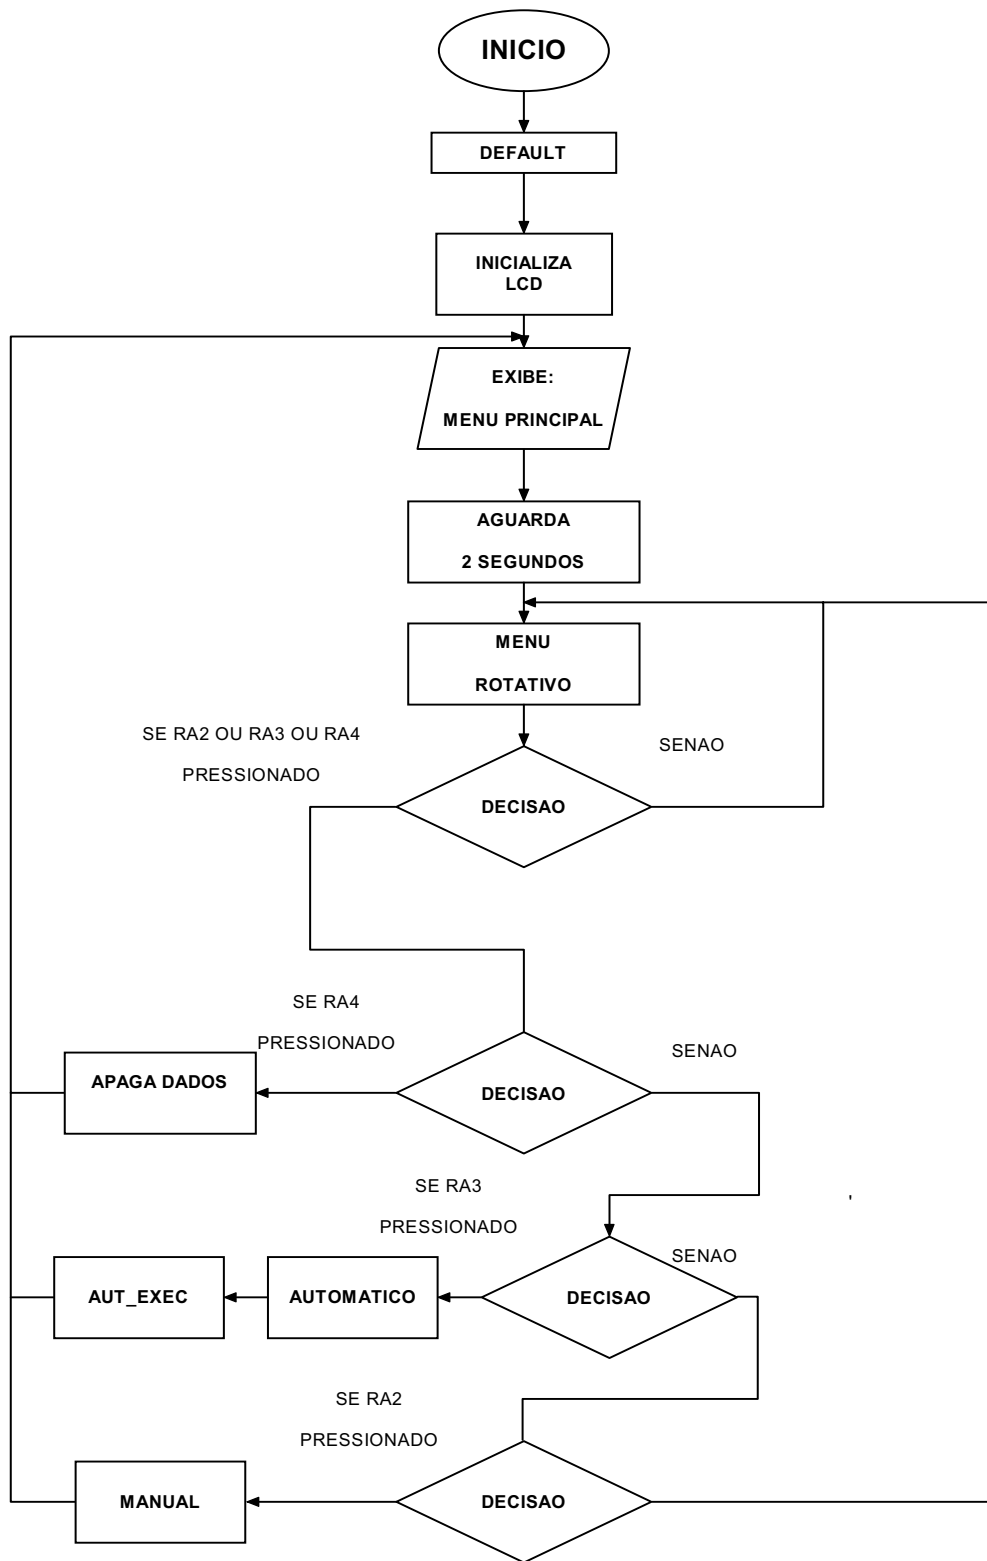


Figura 1G – Fluxograma do circuito da base terra.

APÊNDICE H




Figura 1H – Fluxograma do circuito da base remota.

APÊNDICE I




Figura 1I – Esquema do circuito eletrônico da base remota e base terra.