

Instrumentação avançada em ciência do solo



Ladislau Martin Neto
Carlos Manoel Pedro Vaz
Silvio Crestana

Editores

Empresa Brasileira de Pesquisa Agropecuária	5
Embrapa Instrumentação Agropecuária	5
Ministério da Agricultura, Pecuária e Abastecimento	5
	1
	3
	3
	5
Instrumentação avançada em ciência do solo	5
	4
	5
	5
	5
<i>Editores</i>	5
Ladislau Martin Neto	5
Carlos Manoel Pedro Vaz	5
Sílvio Crestana	5
	0
	1
	1
	3
	6
	7
Embrapa Instrumentação Agropecuária	8
São Carlos, SP	9
2007	7

Exemplares dessa publicação podem ser adquiridos na:

Embrapa Instrumentação Agropecuária

Rua XV de novembro, 1452
 Caixa Postal 741
 CEP 13560-970 – São Carlos-SP
 Fone: (16) 2107-2800
 Fax: (16) 2107-2902
<http://www.cnpdia.embrapa.br>
 e-mail: sac@cnpdia.embrapa.br

Comitê de Publicações da Unidade

Presidente: Dr. Carlos Manoel Pedro Vaz
 Membros: Dra. Débora Marcondes Bastos Pereira Milori,
 Dr. João de Mendonça Naime,
 Dr. Washington Luiz de Barros Melo,
 Valéria de Fátima Cardoso
 Membro Suplente: Dr. Paulo Sérgio de Paula Herrmann Júnior

Supervisor editorial: Dr. Victor Bertucci Neto
 Normalização Bibliográfica: Valéria de Fátima Cardoso
 Capa: Alex Paixão e Valentim Monzane
 Foto da capa: Lúcio André do Castro Jorge e Valentim Monzane
 Editoração eletrônica: Carlos Manoel Pedro Vaz e Emerson de Stefani

1^a edição

1^a impressão (2007): tiragem: 350

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte,
 constitui violação dos direitos autorais (Lei no 9.610).

CIP-Brasil. Catalogação-na-publicação.
Embrapa Instrumentação Agropecuária

159 Instrumentação avançada em ciência do solo. / Ladislau Martin Neto, Carlos
 Manoel Pedro Vaz, Sílvio Crestana editores. – São Carlos:
 Embrapa Instrumentação Agropecuária, 2007.
 438 p.

ISBN: 85-86463-14-0

1. Solos. 2. Métodos Avançados. 3. Equipamentos. 4. Instrumentos. 5. Modelamento
 6. Imagem. I. Martin Neto, Ladislau. II. Vaz, Carlos Manoel Pedro. III. Crestana, Sílvio.

conservation management using the SWAT model. **Biosystems Engineering**, v. 85, n. 3, p. 365-379, 2003.

TUCCI, C. E. M. **Modelos Hidrológicos**. 1. ed. Porto Alegre-RS: Editora da UFRGS / ABRH, 1998. v. 1. 652 p.

WATTS, G. Hydrological Modelling in practice. In: WILBY, R. L. (Ed.). **Comtemporary Hydrology**. Chichester: John Wiley & Sons, 1997.

WILLIAMS, J. R. The physical components of the EPIC model. In: EL-SWAIFY, S. A.; MOLDENHAUER, W. C.; LO, A. (Ed.). **Soil Erosion and Conservation**. Ankeny: Soil Conservation Society of America, 1985. p. 272-284.

WILLIAMS; J. R.; NICKS, A. D.; ARNOLD, J. G. Simulator for water resources in rural basins. **Journal of Hydraulic Engineering**, v. 111, n. 6, p. 970-986, 1985.

WISCHMEIER, W. H.; SMITH, D. D. **Predicting rainfall erosion losses**: a guide to conservation planning. Washington: USDA/ARS, 1978. 58 p. (Agricultural Handbook, no. 573).

YOUNG, R. A.; ONSTAD, C. A.; BOSH, D. D.; ANDERSON, P. **AGNPS**: An Agricultural Non-point source pollution model: A watershed analysis tool. Washington DC, USA: US Department of Agriculture, 1987. (Conservation Research Report, 35).

Capítulo 8

Processamento de Imagens em Ciência do Solo - raízes, morfologia e cobertura do solo

Lúcio André de Castro Jorge

Silvio Crestana

Introdução

A motivação ao estudo de técnicas de processamento e análise de imagens digitais aplicadas à Ciência do Solo, tais como: estudo do sistema radicular, morfologia e cobertura do solo, dentre outras, surge da possibilidade de obtenção de informações complementares às técnicas experimentais convencionais, de tempo e custo muito elevados, permitindo o desenvolvimento de ferramentas mais precisas, rápidas e de custo reduzido.

No estudo do sistema radicular o processamento de imagens facilita a determinação do comprimento, da área superficial, do volume e da análise da distribuição radicular ao longo do perfil de solo. Estes parâmetros, quando calculados manualmente, são extremamente trabalhosos, sendo este o motivo dos estudos do sistema radicular terem tido avanço mais significativo após a introdução de técnicas de imagens.

No estudo da morfologia do solo (agregados e poros), a sua caracterização por meio de técnicas de imagens facilita a análise e permite maior rapidez nas análises.

No estudo da cobertura do solo por imagens, tem-se uma forte contribuição na avaliação das características físicas, como teores de matéria orgânica e textura dos diversos tipos de solos, pois estas são correlacionadas com a resposta espectral registrada em imagens provenientes dos campos. Ainda que influenciadas por outras variáveis como tratos culturais, umidade, adequada seleção de bandas espectrais e resolução espacial, as imagens podem proporcionar uma boa caracterização dos solos dentro de um campo de cultivo, gerando identificação de zonas homogêneas de propriedades físicas do solo. O uso de técnicas de processamento de imagens pode ser uma ferramenta

poderosa para a interpolação de parâmetros de amostras de solo coletadas em campo, ajustando os modelos de interpretação de maneira a produzir um excelente mapa de sítios homogêneos, os quais servem de base para a definição de tratos culturais e aplicações diferenciadas dentro do campo. Ainda assim, muitos cultivos principais e secundários são avaliados em relação a sua taxa de cobertura do solo visando, principalmente, a sua proteção contra o impacto das gotas de chuva. Estas causam, dentre outros efeitos, um selamento superficial do solo e processos de erosão. Imagens de alta resolução permitem calcular a cobertura do solo com precisão e alimentam modelos de previsibilidade de erosão permitindo, assim, uma ação preventiva e corretiva. Estas técnicas são úteis também para manejos como o plantio direto onde se torna importante a determinação de matéria seca sobre o solo.

Introdução ao processamento de imagens

Por *Processamento Digital de Imagens* entende-se a manipulação e interpretação de imagens digitais por computador. Os principais objetivos são de melhorar o aspecto visual de certas feições estruturais contidas nas imagens para interpretação humana e fornecer subsídios para a análise automática por computador de informações extraídas de uma cena. Suas aplicações permeiam quase todos os ramos da atividade humana.

Na Figura 1 são apresentadas algumas das principais etapas para processamento de imagens digitais. A primeira consiste na *aquisição da imagem* e conversão da informação analógica para o formato digital. Após a imagem ter sido digitalizada e armazenada, técnicas de *pré-processamento* podem ser utilizadas para melhorar a sua qualidade, que consistem na maior parte das vezes, de transformações lineares e não-lineares aplicadas a ela visando o melhoramento de contraste, remoção de ruído, regiões de interesse, descorrelação e codificação das informações para sua transmissão, reamostragem dos pixels em uma nova escala, treinamento e extração de características de imagem para segmentação, etc. Muitas aplicações requerem apenas operações de pré-processamento.

Após o pré-processamento de uma imagem para realçar suas características mais relevantes, o próximo passo consiste na *segmentação* dos objetos de interesse presentes nela. Estes objetos podem ser, por exemplo, as raízes das plantas, os poros, os agregados de solo e vários temas de uma imagem aérea.

A segmentação de imagens particiona a imagem em regiões disjuntas com algum significado para a aplicação. Por exemplo, pode-se separar um objeto de interesse do resto da imagem particionando-a em duas regiões, o objeto e o fundo.

A saída da segmentação pode ser a fronteira do objeto com seu exterior ou os pontos de seu interior. Isto define duas formas de representação para o objeto. A representação consiste, portanto, nas várias formas de armazenar a fronteira e o interior de objetos segmentados. Esta nova representação da imagem contém informações sobre a forma e a topologia dos objetos.

Uma vez segmentados os objetos, utilizam-se técnicas de *análise* para classificação e caracterização dos mesmos com base na forma e topologia obtidas.

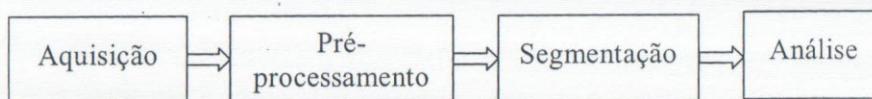


Figura 1. Etapas do processamento de imagens.

Um dos grandes problemas em processamento e análise de imagens refere-se à extração das componentes de interesse contidas na cena original. A análise do conteúdo desta cena depende das duas últimas etapas da Figura 1. Uma relativa à *segmentação*, consistindo de transformações geralmente dependentes da aplicação, e outra referente à *análise quantitativa* dos objetos segmentados. Esta etapa visa a extração de características dos objetos a serem considerados.

Definição de uma imagem digital

Uma imagem digital pode ser entendida como sendo uma cena real que foi digitalizada, ou seja, convertida em uma função de representação discreta. O processo de discretização faz uma amostragem na cena e converte-a em uma imagem digital que pode ser representada por uma matriz de M por N pontos, cada qual denominado *pixel*. A cada *pixel* é atribuído um valor n discreto de intensidade ou de cor.

A resolução espacial determina o nível de detalhamento de objetos que serão discriminados numa imagem. Representa o número de *pixels* vertical e horizontal de uma imagem. Quanto mais *pixels*, mais detalhada é a imagem.

podem ser representados na imagem. A largura da faixa do espectro eletromagnético captada pelo sensor define outra resolução, a resolução espectral. Esta resolução vai definir se a imagem é colorida, monocromática, ou de alguma banda especial do espectro. A resolução radiométrica determinará o intervalo de níveis de cinza ou cores da imagem. Esta resolução define a resolução em cores de cada *pixel* da imagem.

Na especificação do processo de digitalização deve-se decidir quais valores de *M*, *N* e *n* são adequados, do ponto de vista de qualidade da imagem, da quantidade de bytes necessários para armazená-la e do desempenho computacional requerido.

Processamentos básicos

Existe uma infinidade de técnicas de processamento de imagens descritas em diferentes livros de processamento de imagens (JAIN, 1989; GONZALEZ e WINTZ, 1987) e artigos científicos. Esta área da ciência tem avançado significativamente nos últimos anos e se tornado referência em muitas aplicações.

Neste capítulo, serão selecionados alguns processamentos utilizados e considerados importantes para a Ciência do Solo. Dentre eles, destacam-se as técnicas de segmentação de imagens, alguns processamentos básicos de realce, conceitos de morfologia matemática e análise.

Pré-processamento

Dependendo do processo de aquisição da imagem, os valores de cor ou tons de cada pixel da imagem se concentram em uma pequena faixa de valores, resultando numa imagem escura ou clara que pode esconder alguns detalhes. Neste caso, é necessário fazer um pré-processamento de realce de contraste mudando os valores originais de intensidade de modo a utilizar melhor a faixa de valores numéricos disponíveis, aumentando-se assim o contraste entre os objetos de uma cena e seu fundo.

A chave para se entender as técnicas de realce por contraste, consiste em entender o conceito de histograma de uma imagem. Um histograma é uma representação gráfica dos valores de intensidade, ou cor, contidos em uma imagem. Para imagens em tons de cinza, esses valores variam de 0 a 255, podendo ser representados graficamente como sendo o eixo *x* do gráfico de ocorrências de cada um desses valores, conforme a Figura 2.

Quando são imagens coloridas, em geral são três gráficos, um para cada componente de cor, ou seja, R (vermelho), G (verde) e B (azul), sendo cada um deles variando de 0 a 255, no eixo *x*.

Na Figura 2 é apresentado um exemplo de uma imagem de perfil de solo típico obtida em tons de cinza e o respectivo histograma. Da mesma forma, pode ser visualizada uma imagem aérea típica colorida com o histograma nas três bandas RGB.

Por meio da manipulação do histograma de uma imagem, é possível aplicar vários realces na imagem. O objetivo da técnica é expandir faixas estreitas de valores de intensidades tipicamente presentes em uma imagem para uma faixa mais ampla. Esta é uma das técnicas mais simples de realce por manipulação do histograma. Ela envolve a identificação dos limites inferior e superior do histograma e a aplicação de uma transformação linear, logarítmica ou exponencial para aumentar sua faixa estreita para toda a faixa existente de níveis de cinza. Um aumento linear expande uniformemente esta pequena faixa para que a mesma cubra toda a faixa de valores de 0 a 255. Isto aumenta o contraste na imagem com áreas de tons claros aparecendo mais claras e áreas de tons escuros aparecendo mais escuras.

Outra forma de pré-processamento, muito utilizada na Ciência do Solo, é a filtragem por meio da operação de convolução, aplicando-se uma máscara sobre a imagem. A máscara é uma pequena matriz de pesos, geralmente quadrada, que é deslocada sobre a imagem original, a fim de obter cada pixel da imagem convoluída. A operação de convolução, no caso discreto, é dada por:

$$y(m, n) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N h(m-i, n-j)x(i, j)$$

para $m = 1, 2, \dots, I+M$ e $n = 1, 2, \dots, J+N$, onde x é a imagem original, representada como uma matriz de ordem $[M \times N]$, h é a máscara que se deseja aplicar sobre a imagem, representada como uma matriz de ordem $[I \times J]$ e y é a imagem resultante da convolução, que será uma matriz de ordem $[(I+M-1) \times (J+N-1)]$.

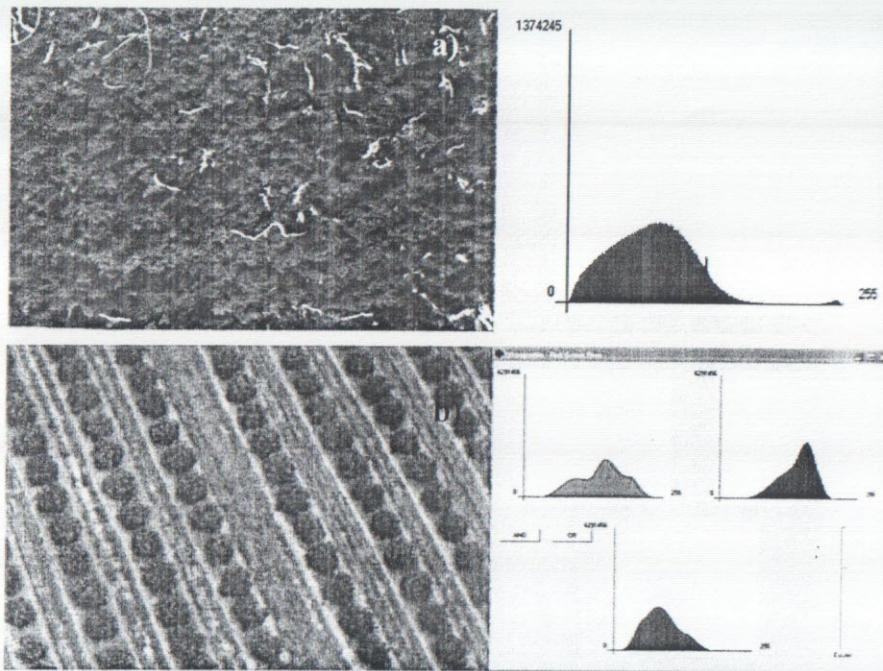


Figura 2. Imagem em tons de cinza de perfil de raízes (a) e colorida de aérea de citros (b) e respectivos histogramas.

Em geral, para cada efeito desejado utiliza-se uma máscara diferente. Desta forma, muitos softwares permitem abrir, criar, editar e salvar suas próprias máscaras, conforme mostra a Figura 3.

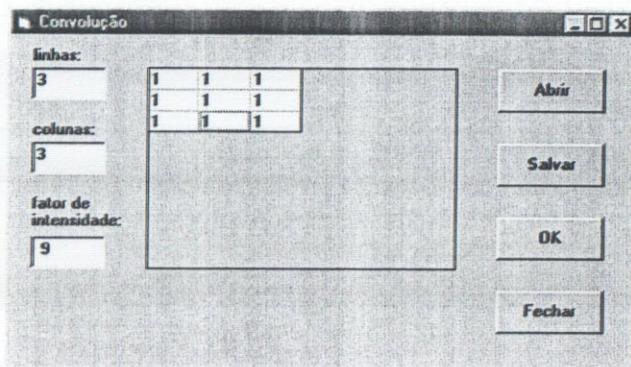


Figura 3. Máscara de média para suavização da imagem.

A aplicação de diferentes máscaras resultará em diferentes filtragens sobre uma imagem, podendo retirar ruídos, intensificar ou eliminar as bordas, etc. Um exemplo usado nas imagens aéreas é o filtro de suavização da imagem através da média dos pixels, conforme pode ser visto na imagem da Figura 4. Este filtro reduz os ruídos da imagem e facilita o processo de segmentação.

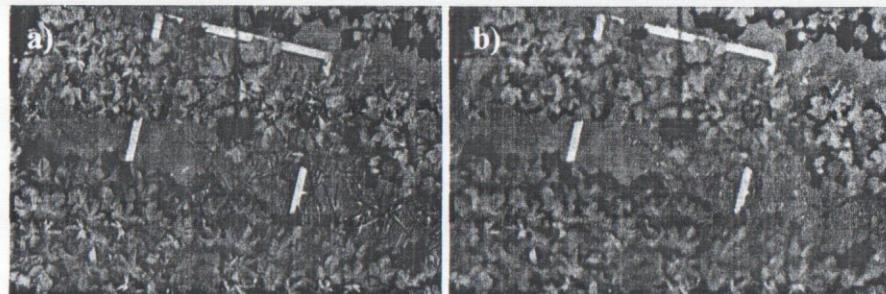


Figura 4. Imagem original de cobertura do solo (a) e o resultado da suavização (b).

Segmentação

A segmentação de imagens é um processo que tipicamente partitiona o domínio espacial de uma imagem em subconjuntos mutuamente exclusivos, chamados regiões, onde cada região é uniforme e homogênea com respeito a algumas propriedades como tom ou textura e cujos valores diferem, em alguns aspectos e significados, das propriedades de cada região vizinha. Um bom processo de segmentação deve resultar em regiões que sejam uniformes e homogêneas com respeito a alguma característica. Por exemplo, nível de cinza ou textura. Regiões adjacentes devem ter valores significativamente diferentes com respeito à característica segmentada.

Segundo Nevatia (1986), a segmentação é a operação de separar os componentes de uma imagem em subconjuntos que correspondem a objetos ou regiões, e a classificação tem por objetivo classificar cada objeto em diferentes categorias. A segmentação pode ser implementada por diferentes técnicas, como por exemplo, a limiarização (*thresholding*), detecção de bordas e extração de regiões. Dentre estas abordagens, a extração de regiões pode ser resultante de uma operação de classificação dos pixels, que utiliza desde técnicas de agrupamento (*clustering*) até a simples classificação individual de cada pixel.

Segundo Jain (1989), os processos de classificação e segmentação são fortemente relacionados. A classificação pode proporcionar a segmentação e vice-versa. A classificação dos pixels de uma imagem é uma forma de rotular seus componentes e pode resultar na segmentação dos seus vários objetos. Um exemplo, em sensoriamento remoto, é a classificação de dados multiespectrais para cada pixel, resultando na segmentação de várias regiões com diferentes culturas ou com mata nativa, dentre outras. Na análise de raízes, a segmentação resulta na identificação de cada segmento de raiz presente na imagem.

Os métodos clássicos de segmentação estão divididos em três grandes grupos: limiarização, segmentação por bordas e segmentação por regiões. Outras abordagens têm sido utilizadas, como o uso de redes neurais, algoritmos genéticos, técnicas de classificação e restauração por métodos estocásticos Sonka et al., (1999). A seguir são descritos alguns processos de segmentação.

Limiarização

A limiarização representa o processo mais simples de segmentação. A limiarização é a transformação da imagem de entrada $f(x,y)$ gerando uma imagem de saída $g(x,y)$ da seguinte forma: $g(x,y) = 1$ para $f(x,y) \geq T$ e $g(x,y) = 0$ para $f(x,y) < T$, em que T é o limiar escolhido para se estabelecer a segmentação. Como resultado tem-se uma imagem binária, onde, geralmente o objeto e/ou a região de interesse são classificados com valor “1” e o fundo ou o restante com valor “0”.

Quando um único limiar é aplicado à imagem toda, o processo é chamado de limiarização global. Quando aplicado utilizando informação de partes da imagem é denominado de limiarização local. Em muitos casos, a limiarização global resulta numa boa segmentação, porém geralmente a limiarização local apresenta resultados mais precisos.

A segmentação automática por meio do uso de limiar é feita com métodos de detecção automática do nível de limiarização. Se algumas propriedades da imagem são conhecidas previamente, a escolha do limiar para segmentação é simplificada. A detecção do limiar pode ser efetuada de diferentes formas: avaliando a forma do histograma e seus vales, determinando o limiar ótimo, etc. Uma das formas mais utilizadas de limiarização automática é a limiarização de Otsu (1979).

Em histogramas com dois picos bem distintos, o limiar pode ser determinado como o mínimo entre os dois máximos locais. Estes

histogramas mostram a presença de duas características bem distintas na imagem, como pode ser observado na Figura 5. Observando as imagens de raízes da Figura 5a nota-se que as raízes possuem tons escuros, próximos da intensidade zero e o fundo com tom de cinza próximo de 128. Pelo histograma da imagem, apresentado na Figura 5b, nota-se um pico central referente aos tons de cinza do fundo e um pico junto ao eixo do zero relativo às raízes. Neste sentido, uma limiarização com corte no meio entre os dois picos resultaria numa boa segmentação da imagem, como pode ser visto na Figura 5c, onde se faz a segmentação manual selecionando sobre o histograma o melhor limiar T .

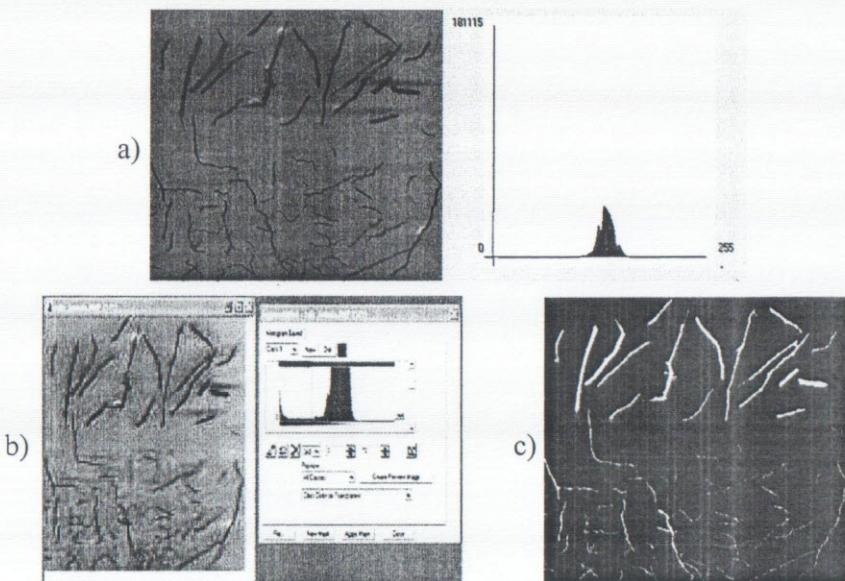


Figura 5. Imagens de raízes e seu histograma (a, b) e tratadas por limiarização manual direta no histograma (c).

Limiarização de Otsu

O método de limiarização bimodal de Otsu (OTSU, 1979) é baseado na análise de discriminante. A operação de limiarização é considerada como sendo o particionamento dos pixels de uma imagem de l níveis de cinza em duas classes, C_0 e C_1 , que podem representar o objeto e o fundo, ou vice-versa, ocorrendo esta partição no nível de cinza t . Desta forma, $C_0 = \{0, 1, \dots, t\}$ e $C_1 = \{t + 1, t + 2, \dots, l\}$. Seja σ_w^2 a variância dentro da classe, σ_B^2 a variância entre as classes e σ_T^2 a variância total. Um limiar

ótimo pode ser obtido pela minimização de uma das funções critérios seguintes:

$$\lambda = \frac{\sigma_B^2}{\sigma_W^2}; \quad \eta = \frac{\sigma_B^2}{\sigma_T^2}; \quad k = \frac{\sigma_T^2}{\sigma_W^2}$$

Das três funções critérios apresentadas acima, η é a mais simples, logo. o limiar ótimo t^* é definido por:

$$t^* = \operatorname{Argmax} \eta$$

onde: $\sigma_T^2 = \sum_{i=0}^{l-1} (i - \mu_T)^2 P_i$

sendo: $\mu_T = \sum_{i=0}^{l-1} i P_i$ e $\sigma_B^2 = \omega_0 \omega_1 (\mu_1 \mu_0)^2$

sendo: $\omega_0 = \sum_{i=0}^t P_i$ e $\omega_1 = 1 - \omega_0$

$$\mu_1 = \frac{\mu T - \mu_t}{1 - \mu_0}; \quad \mu_0 = \frac{\mu_t}{\omega_0}; \quad \mu_t = \sum_{i=0}^t i P_i$$

e $P_i = \frac{n_i}{n}$

onde n_i é o número de pixels com nível de cinza i e n é o número total de pixels de uma dada imagem definida como:

$$n_i = \sum_{i=0}^{l-1} n$$

Além disso, P_i é a probabilidade de ocorrência do nível de cinza i .

O método de Otsu como proposto disponibiliza meios para se analisar outros aspectos além da seleção de um limiar ótimo para uma dada imagem. Para a seleção do limiar t^* de uma imagem, as classes de probabilidades ω_0 e ω_1 indicam as porções das áreas ocupadas pelas classes C_0 e C_1 . As médias de classes μ_0 e μ_1 servem como estimativa dos níveis médios das classes na imagem original em níveis de cinza. Além disso, o valor máximo de η , denotado por η^* , pode ser usado como medida para avaliar a separabilidade das classes C_0 e C_1 na imagem original ou a bimodalidade do histograma. Esta é uma medida bastante

significativa, pois é invariante para transformações afins da escala de níveis de cinza e é determinada unicamente dentro do intervalo $0 \leq \eta \leq 1$.

O limite inferior (zero) é obtido somente quando uma dada imagem tenha um nível de cinza único e constante, e o limite superior (um) é obtido somente quando imagens de dois valores são dadas.

Em imagens digitais, a uniformidade dos objetos tem papel importante na separação destes objetos do fundo. De fato, a abordagem de Otsu para limiarização de imagens em nível de cinza é eficiente com base na uniformidade medida entre as duas classes C_0 e C_1 a serem segmentadas. O método proposto se caracteriza por sua natureza não paramétrica e não supervisionada de seleção de limiar e tem as seguintes vantagens:

- O processo como um todo é muito simples. São utilizados somente os momentos cumulativos zero e de primeira ordem do histograma de níveis de cinza;

- Uma extensão direta para problemas que exijam vários limiares é viabilizada face ao critério no qual o método está baseado, ou seja, a análise de discriminantes;

- Um limiar ótimo (ou conjunto de limiares) é selecionado de forma automática e estável, não baseado na diferenciação (uma propriedade local como um vale), mas sim na integração (propriedade global) do histograma;

- Viabiliza a análise de outros aspectos importantes, tais como estimativa dos níveis médios das classes, avaliação da separabilidade das classes, etc;

- O método é extremamente genérico; cobre um largo escopo de processos de decisão não supervisionados; o conjunto de suas aplicações não se limita a binarização de imagens em níveis de cinza tal como descrito anteriormente, mas também pode ser utilizado em outros casos de classificação não supervisionada no qual um histograma de alguma característica discriminativa que classifique objetos esteja disponibilizado.

Cabe ressaltar, no entanto, que o limiar calculado não é apropriado para imagens nas quais as variâncias dos níveis de cinza de objetos e fundo ou populações de pixels correspondentes sejam extremamente diferentes.

Na Figura 6 pode ser visto uma limiarização por Otsu comparada com uma limiarização manual. O resultado é totalmente aceitável para esta aplicação.

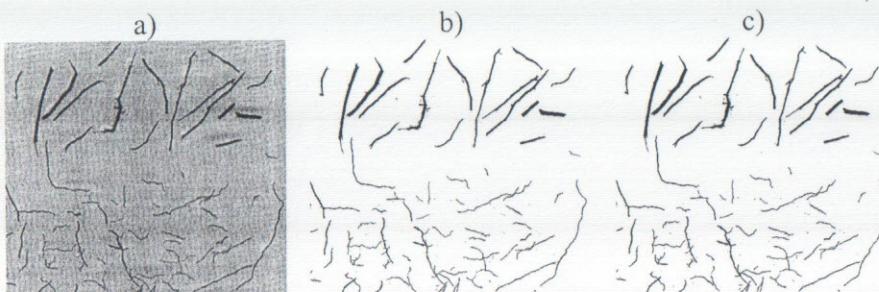


Figura 6. Imagem de raízes (a) e tratadas com segmentação por limiarização manual (b) automática por Otsu (c).

Segmentação por regiões

A segmentação por regiões baseia-se em técnicas que procuram separar regiões com características homogêneas. A forma mais simples é a do crescimento de regiões, que deve satisfazer a condição de que a imagem seja formada pela união de todas as regiões encontradas, que estas não tenham interseção e que sejam homogêneas. Também que representem as características distintas utilizadas para a segmentação.

Basicamente, três abordagens aparecem no crescimento de regiões: união de regiões, divisão de regiões e união-divisão de regiões. A união de regiões inicia-se com uma imagem segmentada. As regiões são unidas para satisfazer a condição que continua formando um conjunto homogêneo. A divisão da imagem é o oposto, inicia-se com a imagem segmentada, ou não, porém com regiões não homogêneas. Começa-se a subdivisão da mesma de tal forma que as regiões formadas na divisão sejam homogêneas. Por fim, a combinação união-divisão, une os dois processamentos anteriores.

Um algoritmo muito utilizado para crescimento de regiões parte de uma semente, normalmente indicada interativamente, depois faz a busca nos vizinhos até que todas as condições de semelhança sejam testadas. Ao final deste procedimento, a região é formada, (PHILIPP, 1999). Os métodos de crescimento de regiões sempre resultam ou em muitas regiões ou em poucas regiões. Para melhorar os resultados, uma grande quantidade de pós-processamentos tem sido feita.

Segmentação por cor

A cor é uma característica com grande potencial discriminatório. Em diversas situações, o homem toma por base essa informação para

diferenciar objetos ou estruturas. Há casos, em que a cor é adicionada ao processo artificialmente, por meio do uso de corantes. Isso é comum em estudos microscópicos, quando se torna necessário o destaque de estruturas de interesse específico.

Na análise automática de imagens, o processamento da cor é de grande importância na identificação e extração de características e objetos. Este fato deve-se principalmente ao aumento da capacidade de discernimento dos objetos em imagens coloridas. Entretanto, para aplicar a cor em processamento de imagens, é fundamental que se tenha conhecimento dos principais sistemas de representação desta informação.

Os sistemas de representação de cor, de uma forma geral, fornecem uma padronização para ela, permitindo a sua quantificação, independente das condições psicofísicas dos observadores. Vários são os sistemas para a representação da cor encontrados na literatura; as duas principais abordagens são:

- RGB: consiste na utilização de um espaço tridimensional onde cada cor é obtida a partir das cores primárias vermelha (R), verde (G) e azul (B), respectivamente baixa, média e alta freqüências do espectro percebido pelo olho humano.

- HSI: H é a matiz (descreve a cor pura: vermelha, azul, amarela); S a saturação da cor (grau de pureza); I é a componente que representa a intensidade de luz (brilho) da cor.

Vários autores apresentam diferentes formas de utilizar a cor como característica discriminante. Ohta et al. (1980) realizaram um estudo comparativo entre diversos sistemas de representação de cor, buscando as componentes mais significativas para segmentação de imagens coloridas. Uma abordagem parecida foi apresentada por Ohlander et al. (1978).

Carevic e Caelli (1997) utilizaram o mesmo sistema de componentes introduzidos por Ohta et al. (1980) e a aplicação da Transformada de “Hotelling” (TH) numa técnica de agrupamento, ou *clustering*, que se mostrou bastante eficiente na identificação de regiões auto-similares da imagem. A TH é muito utilizada nas aplicações da Ciência do Solo.

Jorge (2001) mostrou o resultado da segmentação de imagens aéreas por cor utilizando diferentes modelos de redes neurais artificiais e apresentou uma boa revisão das técnicas de segmentação por cor.

Do ponto de vista computacional, o processamento da informação cor implica em considerável aumento dos custos, além de necessitar de um

espaço de armazenamento três vezes maior. Em algumas aplicações, observa-se a transformação de imagens originalmente coloridas para níveis de cinza. Mas nem sempre o contraste da imagem monocromática é suficiente para a obtenção de bons resultados no processamento de imagens, principalmente quando o objetivo é a segmentação.

Segmentação por textura

Textura pode ser entendida como um ou mais padrões locais básicos que são repetidos periodicamente. Entretanto, não está claro exatamente qual é o padrão, como ele é repetido e se a textura é uma propriedade inerente a todos os objetos, se alguns são desprovidos totalmente de textura. Segmentar por textura é particionar uma imagem em regiões, onde cada região contém uma textura simples e distinta de seus vizinhos.

A textura pode ser representada por modelos que fornecem um meio para transformar uma janela de uma imagem em um conjunto de números. Esses modelos de textura podem ter três classificações principais: estruturas de imagens piramidais, campos randômicos e métodos estatísticos.

O objetivo das estruturas de imagens piramidais é gerar um número de parâmetros homogêneos que representem a resposta de um banco de filtros em escalas variadas e possíveis orientações diferentes. Existem muitos tipos de filtros que podem ser usados para este propósito, como o filtro Laplaciano, o filtro de Gabor e Wavelets.

Os modelos de campos randômicos assumem que os valores dos pixels são escolhidos por um processo estocástico bidimensional. As duas classes principais são: Campos Randômicos de Markov Gaussiano (*Gaussian Markov Random Fields* - GMRF's), que utilizam a distribuição de probabilidade Gaussiana; Campos Randômicos de Gibbs (*Gibbs Random Fields* - GRF's), que utilizam a distribuição de probabilidade exponencial. Ambas obedecem às propriedades de Markov, que declara o seguinte: "a probabilidade que o pixel tem de ter certo nível de cinza dados todos os outros pixels da imagem é igual à probabilidade que o pixel tem de ter o mesmo nível de cinza dados somente os seus pixels vizinhos" (LIU et al., 1999).

A classe dos métodos estatísticos agrupa várias técnicas:

- *Matriz de co-ocorrência*: representa a distância entre pixels e a dependência espacial dos níveis de cinza para diferentes orientações.

- *Transformada Discreta de Fourier e Transformada Discreta de Coseno*: são dois exemplos de uma classe geral de técnicas matemáticas chamadas transformadas ortogonais. Geralmente, um conjunto de funções ortogonais fundamentais é gerado, e, então, com cada função aplica-se a convolução com a imagem para produzir um conjunto de números para cada ponto.

- *Fractais*: são aplicados, às vezes, para a análise e segmentação de textura, porque eles possuem uma escala própria. Isto significa que uma análise fractal pode produzir a dimensão fractal da textura e indicar a escala. Desta forma, evita-se ter de adivinhar em que escala a análise deve proceder.

Na literatura, encontram-se vários trabalhos relacionados com as diversas técnicas de análise de texturas (BATISTA-NETO, 1996; HARALICK e SHAPIRO, 1992).

Segmentação por redes neurais artificiais

Uma rede neural (RN) é uma coleção de unidades de processamento, chamadas de neurônios, dispostos em uma estrutura de uma ou várias camadas e conectados uns aos outros de forma paralela. Reagem coletivamente a um dado estímulo e produzem uma única resposta global. Uma rede neural tem a habilidade de aprender um dado tipo de conhecimento, armazenar este conhecimento e usá-lo mais tarde para executar uma tarefa. Algumas das suas vantagens são: paralelismo, memória distribuída, capacidade de adaptação, tolerância a falhas e robustez diante de ruídos.

O conhecimento de uma rede neural artificial (RNA) está na estrutura das conexões entre as unidades (neurônios) que a compõe. A cada conexão associa-se um peso (valor numérico) que caracteriza a força da conexão entre dois neurônios. O aprendizado em uma RNA é realizado por um processo de adaptação dos seus pesos.

Os conhecimentos das redes se resumem a um conjunto de valores numéricos descrevendo as conexões, e por consequência, estes valores descrevem também o comportamento da rede. A escolha do tipo de neurônio artificial utilizado é fundamental para se definir como será a representação interna dos conhecimentos da rede.

Cada unidade da rede é dotada de um estado interno, denominado estado de ativação. As unidades podem propagar seu estado de ativação para as outras unidades através das conexões existentes. A regra que determina a

ativação de um neurônio em função das entradas, ponderadas pelos respectivos pesos, se chama regra de ativação ou função de ativação.

Alterações nas conexões e na estrutura da rede é o que permite realizar o aprendizado de um novo comportamento. Desta maneira, pode-se modificar o estado de ativação na saída da rede em resposta a uma determinada configuração de entradas. Portanto, a rede é capaz de estabelecer associações de entrada-saída (estímulo e resposta) para se adaptar a uma situação proposta. No caso de uma rede com aprendizado supervisionado, a rede deve adaptar os seus pesos de maneira que possa responder de acordo com o exemplo dado, ou seja, gerando na sua saída um estado de ativação compatível para com o esperado. O método utilizado para modificar o comportamento de uma rede é denominado de regra de aprendizado.

A forma de aprendizado é, em geral, um processo gradual e iterativo, em que os pesos são modificados várias vezes, pouco a pouco, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados. O aprendizado é realizado utilizando-se um conjunto de dados disponível para aprendizado (base de exemplos). Pode ser classificado como:

- *Aprendizado supervisionado*: o usuário dispõe de um comportamento de referência preciso que ele deseja ensinar para a rede. A rede deve ser capaz de medir a diferença entre seu comportamento atual e o comportamento de referência e corrigir os pesos de maneira a reduzir este erro (desvio de comportamento em relação aos exemplos de referência). Nos casos de problemas de classificação, a saída é a classe à qual cada exemplo está associado.

- *Aprendizado não-supervisionado*: os pesos da rede são modificados em função de critérios internos, por exemplo, a repetição de padrões de ativação em paralelo de vários neurônios. O comportamento resultante deste tipo de aprendizado é usualmente comparado com técnicas de análise de dados empregadas na estatística (*clustering*).

A maneira pela qual a rede é alimentada pelos dados pode ser:

- *Aprendizado por pacotes*: o conjunto de dados de aprendizado é apresentado à rede várias vezes de modo que é possível otimizar a resposta da rede, reduzindo os erros e minimizando o erro obtido na sua saída. Tal modo de aprendizado é caracterizado por trabalhar com uma alteração dos pesos para cada época, ou seja, para cada passagem completa de todos os exemplos da base de aprendizado.

- *Aprendizado contínuo*: o algoritmo de aprendizado leva em consideração continuamente os exemplos que lhe são repassados. Se o conjunto de dados é bem delimitado, denomina-se este método de aprendizado on-line. Uma rede com uma grande facilidade de adaptação pode “esquecer” rapidamente os conhecimentos anteriormente adquiridos e uma rede com uma grande estabilidade pode ser incapaz de incorporar novos conhecimentos.

A adaptação/otimização dos pesos também pode ser implementada por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado:

- *Métodos de correção do erro*: Exemplos de modelos deste tipo são: Adaline, Perceptron, Back-Propagation, Cascade-Correlation;
- *Métodos por reforço*: Exemplos: Driver-Reinforcement Learning;
- *Métodos por competição ou por auto-organização*: Exemplos: Kohonen Self-Organizing Feature Maps (SOM), Adptative Ressonance Theory - ART;
- *Métodos através da criação de protótipos ou clusters*: Exemplos: ART1, ART2;
- *Métodos baseados em memórias associativas*: (auto-associativas ou hetero-associativas). Exemplos: Modelo de Hopfield;
- *Métodos de aprendizado de seqüências temporais* (redes recorrentes): Exemplos: BPTT (back propagation temporal).

Outro elemento importante diz respeito a forma como os neurônios armazenam as informações: unidades baseadas em protótipos e unidades do tipo Perceptron.

- *Redes à base de protótipos*: utiliza neurônios que servem para representar protótipos dos exemplos aprendidos. As unidades têm uma representação interna que agrupa as características comuns e típicas de um grupo de exemplos. As redes baseadas em protótipos têm normalmente um aprendizado não supervisionado (com um ou mais protótipos associados a cada classe). Uma das vantagens deste tipo de rede é a possibilidade de fazer um aprendizado contínuo e incremental, uma vez que não é muito difícil de conceber um algoritmo capaz de aumentar a rede neural através da adição de novos protótipos. Os protótipos são também denominados de *clusters*;

- *Redes à base de Perceptrons*: as unidades do tipo Perceptron foram criadas por Frank Rosenblatt em 1950. Este é um dos modelos de neurônios mais utilizados na atualidade. Ele é a base de diversos tipos de RNA com aprendizado supervisionado utilizando uma adaptação por correção de erros (usualmente baseada na descida da superfície de erro usando o gradiente).

Vários autores estudaram a segmentação de imagens usando redes neurais do tipo MLP de três camadas, onde o número de neurônios na camada de entrada depende do número de características de entrada para cada pixel, e o número de neurônios na camada de saída é igual ao número de classes. Em uma rede multicamada para binarizar imagens, a entrada da rede pode ser o histograma, enquanto a saída seria o limiar desejado. Para a fase de treinamento, é preciso um conjunto grande de amostras de imagens com limiares conhecidos que produzam saídas adequadas. Na prática, é muito difícil obter um número grande de amostras de imagens com limiares conhecidos (JESUS, 1999).

A abordagem neural também é aplicada na segmentação de texturas e na segmentação de imagens coloridas. Yin et al. (2001) utilizaram um tipo variante de rede neural com três camadas para o problema de segmentação em cenas naturais, cuja entrada são os valores RGB dos pixels das imagens. Moreira e Costa (1995) aplicaram uma rede neural do tipo mapas auto-organizáveis (SOM) na segmentação de imagens coloridas. Vehtari e Lampinen (2001) utilizaram uma rede do tipo MLP para a segmentação e a classificação de imagens de uma floresta. Da mesma forma, Andrade e Martins (2001), testaram diferentes arquiteturas no processamento de imagens de satélite. Para a classificação supervisionada de imagens de sensoriamento remoto foram também utilizadas combinações de redes neurais e algoritmos estatísticos (GIACINTO et al., 2000). Jorge (2001) testou diferentes redes neurais para segmentação de imagens aéreas.

Redes neurais probabilísticas (PNN) foram utilizadas para análise de imagens de sementes de milho visando a sua classificação (STEENHOEK et al., 1999). Na segmentação de imagens em profundidade foi feita a aplicação de redes neurais oscilatórias (LIU et al., 1999) e de uma MLP (VARGAS e ROMERO, 2000).

Na determinação de parâmetros para segmentação e identificação de caminhos em sistemas agrícolas autônomos, foi utilizada uma rede MLP em Pinto et al. (1999). Na aplicação em tempo real de herbicidas através da identificação de texturas nas imagens de cobertura do solo foi

utilizada uma rede MLP de três camadas (TANG et al., 1999). A textura e a cor foram utilizadas numa rede SOM para segmentar imagens de cenas naturais (CAMPBELL et al., 1995a; CAMPBELL et al., 1995b; CAMPBELL, 1996).

Uma das redes neurais mais utilizadas em segmentação nas aplicações da Ciência do Solo é a rede neural multicamada do tipo MLP com o algoritmo *backpropagation* (BP), ou de *retro-propagação de erro*, ou simplesmente *retro-propagação*, utilizado no treinamento de redes neurais multicamadas. Devido a grande difusão da rede MLP com esta regra de aprendizagem, é comum referir-se a ela com o nome da própria regra de aprendizagem, ou seja, rede BP.

O algoritmo de retro-propagação consiste em dois passos de computação: o processamento direto e o processamento reverso. No processamento direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede, camada a camada. Durante o processamento direto, os pesos da rede permanecem fixos. No processamento reverso, um sinal de erro calculado na saída da rede é propagado no sentido reverso, camada a camada, e ao final deste processo os pesos são ajustados de acordo com uma regra de correção de erro. O treinamento da rede através de retro-propagação é realizado de forma supervisionada, ou seja, é apresentado à rede o padrão selecionado interativamente e, também, é disponibilizada a resposta desejada para cada padrão de entrada.

O algoritmo *backpropagation* foi criado a partir da generalização da regra de aprendizado *Widrow-Hoff*, que foi introduzida por Bernard Widrow e Marcian Hoff em 1960-1962 para redes do tipo *feedforward perceptron* (JORGE, 2001).

A regra de aprendizado conhecida como “Regra Delta” (LMS - minimização do erro médio quadrático), que ajusta os pesos das conexões entre os neurônios da rede de acordo com o erro, ou seja, esta regra tem como objetivo encontrar um conjunto de pesos e polarizações que minimizem a função erro:

$$E = \frac{1}{2} \sum_{j=1}^R \sum_{i=1}^S (y_{d,j,i} - y_{j,i})^2$$

onde R = número de padrões ou vetores de entrada; S = número de neurônios de saída (dimensão do vetor de saída); $y_{d,j,i}$ = saída desejada no i -ésimo neurônio, quando o j -ésimo padrão é apresentado; $y_{j,i}$ =

saída obtida pela rede no *i*-ésimo neurônio, quando o *j*-ésimo padrão é apresentado.

A alteração dos pesos $W_{i,j}$ da regra delta é calculada da seguinte maneira:

$$\Delta W_{i,j} = -\eta \frac{\partial E}{\partial W_{i,j}}$$

onde, η = taxa de aprendizado e $\frac{\partial E}{\partial W_{i,j}}$ é a derivada parcial do erro em relação ao peso da respectiva conexão (gradiente).

O algoritmo BP utilizado para treinamento incremental é descrito pelos seguintes passos:

Passo 1: Inicializar os pesos, as polarizações e os demais parâmetros de treinamento;

Passo 2: Apresentar à rede um padrão de entrada do conjunto de treinamento e computar a sua saída; O conjunto de treinamento é a matriz que representa a janela na qual se seleciona um padrão da classe;

Passo 3: Calcular o erro para os neurônios da camada de saída, subtraindo a saída desejada da saída calculada;

Para um dado vetor de entrada o nível de ativação $v_j^{(l)}(n)$ para o *j*-ésimo neurônio na

$$\text{camada } l \text{ é: } v_j^{(l)}(n) = \sum W_{ji}^{(l)}(n) y_i^{(l-1)}(n)$$

onde $y_i^{(l-1)}(n)$ é o sinal de saída do *i*-ésimo neurônio na camada *l-1* na iteração n e $w_{ji}^{(l)}(n)$ é o peso do neurônio *i* na camada *l-1* para o neurônio *j* na camada *l*.

Assumindo uma função sigmoidal como função de ativação definida por:

$$y(n) = \frac{1}{1+e^{-(vb)}}$$

onde b é responsável pela inclinação da sigmóide e v o nível de ativação.

Assim o erro é calculado por:

$$e(n) = (y_d(n) - y(n))$$

onde: y_d é a saída desejada e y a saída real (saída gerada pela rede).

Passo 4: Calcular os gradientes locais, ou deltas, para ajuste dos pesos. Retro-propagar o erro para as camadas escondidas. Como não existe uma saída desejada para os neurônios das camadas escondidas, deve-se calcular o erro destes a partir do erro dos neurônios pertencentes à camada de saída e das conexões que os interligam.

$$\delta_j^{(l)}(n) = e_j^{(L)}(n) \cdot y_j(n) [1 - y_j(n)]$$

para o neurônio *j* na camada de saída *L*, ou ainda,

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) [1 - y_j(n)] \sum \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n)$$

para o neurônio *j* na camada intermediária *l*.

Passo 5: Têm-se assim, a seguinte equação para calcular o ajuste dos pesos na camada *l* de acordo com a regra delta generalizada:

$$w_{jj}^{(l)}(n+1) = w_{jj}^{(l)}(n) + \alpha [w_{jj}^{(l)}(n) - w_{jj}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_j^{(l-1)}(n)$$

onde η é o parâmetro de velocidade de aprendizado e α é a constante momento. Esta constante é responsável por aumentar a velocidade de aprendizado e evitar o perigo de instabilidade da rede.

Passo 6: Calcular o erro acumulado da rede. Nesta etapa, deve ser verificado se o erro total sobre todos os padrões de entrada pode ser considerado desprezível, isto é, se caiu abaixo de um limiar de aceitação. Se assim for o caso, o algoritmo deve parar; caso contrário, deve-se voltar ao passo 2.

Múltiplas camadas de neurônios não-lineares permitem à rede BP aprender relações lineares e não-lineares existentes entre os valores de entrada e saída. Nesse caso, se a camada de saída for composta por neurônios lineares, a rede pode produzir valores fora do intervalo [0,1]. Em geral, restringe-se a saída da rede a valores no intervalo [0,1] fazendo a camada de saída também consistir de neurônios sigmoidais.

A Figura 7 apresenta a configuração da rede de 3 camadas (1 de entrada, 1 escondida e 1 de saída) utilizada no reconhecimento de três classes de cobertura do solo por Jorge (2001), onde a entrada é o valor RGB.

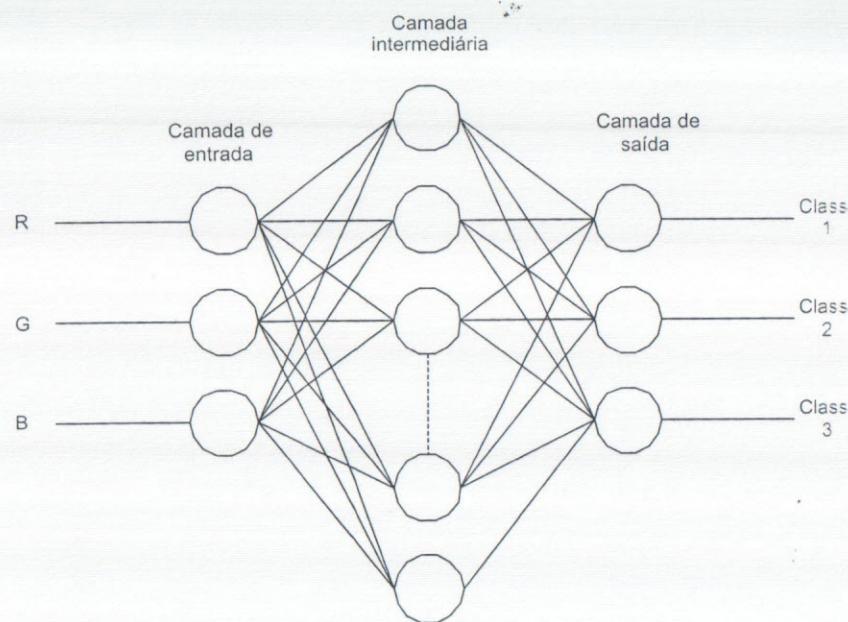


Figura 7. Topologia da rede MLP utilizada.

A verificação da fase de treinamento da rede ocorre através da verificação do erro. Os resultados deste modelo de rede são apresentados no tópico sobre aplicação de imagens aéreas em análise da cobertura do solo.

Segmentação por análise multivariada

A segmentação da imagem, para fazer a extração automática de características e classificação dos *pixels* também pode ser feita pela análise multivariada. A análise multivariada é uma análise estatística responsável por examinar como variáveis dependentes relacionam-se dentro de um determinado conjunto de dados. Tais métodos de análise têm como objetivo a redução e simplificação da complexidade do problema. Na prática, eles podem reduzir o número de variáveis a serem computadas ou eliminar aquelas difíceis de serem observadas ou medidas, garantindo, ainda assim, que informações relevantes não sejam perdidas.

Dentre os objetivos da análise multivariada pode-se destacar: o agrupamento de dados, ou seja, como selecionar variáveis similares a partir de medidas de características; a dependência entre variáveis.

avaliando se são mutuamente independentes ou se existem uma ou mais variáveis que dependem de outras; e a previsão, determinando o relacionamento entre as variáveis com a finalidade de prever os valores de uma ou mais variáveis de interesse.

O método mais utilizado para aplicações em Ciência do Solo é a Transformada de Hotelling. Neste método deseja-se fazer a extração de características, processo através do qual um espaço de dados é transformado em um espaço de características que, teoricamente, tem exatamente a mesma dimensão do espaço de dados original. Todavia, a transformação pode ser projetada de modo que o conjunto de dados possa ser representado por um número reduzido de características relevantes.

Transformada de “Hotelling”

A Transformada de “Hotelling” (TH), também conhecida por Transformada de “Karhunen-Loève”, ou ainda Transformada das Componentes Principais (JORGE, 2001), baseia-se nas propriedades estatísticas de um conjunto de dados, no caso de imagens, no conjunto de cores da imagem.

Esta transformação introduzida por Hotelling faz a análise de componentes principais, uma das técnicas mais conhecidas de análise multivariada. É um dos métodos estatísticos multivariados mais utilizados.

A análise das componentes principais, como o próprio nome sugere, toma p variáveis e procura por combinações lineares dessas que sejam não correlacionadas. A falta de correlação é uma propriedade útil, pois significa que os índices estão medindo diferentes “dimensões” dos dados.

Ao realizar uma análise de componentes principais, espera-se sempre que as variâncias da maioria dos índices sejam tão pequenas que possam ser desprezadas. Nesse caso, a variação do conjunto de dados pode ser descrita adequadamente pelas poucas variáveis cujas variâncias são consideradas não desprezíveis. Assim, consegue-se reduzir o número de variáveis.

Considere um conjunto de M vetores aleatórios da forma:

$$x_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T$$

O vetor médio m_x do conjunto de M vetores pode ser descrito por:

$$m_x = E\{x\} \equiv \frac{1}{M} \sum_{i=1}^M x_i$$

sendo $E\{\text{variável}\}$ o valor esperado da variável.

A matriz de covariância C_x desta população de vetores será dada por:

$$C_x = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ c_{21} & c_{22} & \cdots & c_{2n} \\ \vdots & \vdots & & \vdots \\ c_{n1} & c_{n2} & \cdots & c_{nn} \end{bmatrix}$$

onde o elemento c_{jk} de C_x é dado por:

$$c_{jk} = E\{(x_j - m_j)(x_k - m_k)^T\}$$

sendo x_j , x_k e m_j , m_k o j -ésimo e o k -ésimo componentes de x_i e m_x , respectivamente.

Então a matriz de covariância desta população de vetores será dada por:

$$C_x = E\{(x - m_x)(x - m_x)^T\}$$

sendo x um vetor n -dimensional, a matriz de covariância C_x tem dimensão $n \times n$.

Se x é um vetor real e $x_i x_j = x_j x_i$ a matriz C_x será real e simétrica ($C_{ij} = C_{ji}$). Logo a população de vetores terá seus elementos x_i e x_j descorrelacionados se os elementos $C_{ij} = C_{ji}$ forem iguais a zero.

Expandindo a equação anterior, tem-se:

$$C_x = E\{xx^T - xm_x^T - m_x x^T + m_x m_x^T\} = E\{xx^T\} - m_x m_x^T$$

$$\text{Logo: } C_x = \frac{1}{M} \sum_{i=1}^M x_i x_i^T - m_x m_x^T$$

Como C_x é real e simétrica, pode-se encontrar um conjunto de autovetores ortonormais e dispô-los nas linhas de uma matriz na ordem decrescente dos autovalores λ a que cada autovetor está associado. ou seja, $\lambda_i \geq \lambda_{i+1}$, onde $i=1, 2, \dots, n-1$ é o índice da linha da matriz.

A transformação da forma: $y = A(x - m_x)$ é conhecida como Transformada de "Hotelling" (TH), onde A é a matriz de autovetores citada anteriormente.

No novo sistema resultante da TH, as três novas componentes H , O e T , podem ser obtidas por:

$$\begin{bmatrix} H \\ O \\ T \end{bmatrix} = \begin{bmatrix} E_{11} & E_{12} & E_{13} \\ E_{21} & E_{22} & E_{23} \\ E_{31} & E_{32} & E_{33} \end{bmatrix} \begin{bmatrix} R - m_R \\ G - m_G \\ B - m_B \end{bmatrix}$$

onde $[E_{11}E_{12}E_{13}]$, $[E_{21}E_{22}E_{23}]$ e $[E_{31}E_{32}E_{33}]$ são os autovetores da matriz de covariância.

Propriedades da transformada de "Hotelling"

Pode-se verificar que:

$$E\{y\} = 0; \quad C_y = AC_x A^T; \quad C_y = \begin{bmatrix} \lambda_1 & & 0 \\ & \ddots & \lambda_2 \\ 0 & & \ddots & \lambda_n \end{bmatrix}$$

Uma característica importante da TH é o fato das componentes associadas aos maiores autovalores conterem a maior parte da informação presente no conjunto de M vetores. Alguns sistemas de cores possuem suas componentes totalmente correlacionadas, como é o caso do sistema RGB, mostrando-se pouco indicados quando se deseja fazer a segmentação de cores que se torna muito complicada. A TH pode ser utilizada para descorrelacionar as componentes dos sistemas estudados. As novas componentes H , O e T são descorrelacionadas e apresentam as características presentes na imagem. Pode-se utilizar as componentes de maior variância nos algoritmos de segmentação, reduzindo a dimensão do sistema. Neste caso, a primeira componente, H , é a mais representativa, uma vez que é aquela formada pelo maior autovalor.

Usando-se uma simples limiarização no histograma de H se faz a segmentação de uma imagem colorida com muita precisão. Também, numa segmentação por rede neural, simplifica a entrada para a rede.

Processamento

Existem inúmeros processamentos que podem ser utilizados no estudo de raízes, morfologia do solo e na análise de imagens aéreas. Nesta seção são apresentados apenas alguns dos processamentos mais utilizados para

determinação dos parâmetros de interesse no estudo de raízes, cobertura vegetal e morfologia do solo.

Afinamento ou esqueletonização

A técnica de esqueletonização (*skeletonizing algorithm*) é freqüentemente utilizada para obter o esqueleto de uma região através do seu afinamento. Afinamento é o processo de redução de uma forma para uma versão simplificada que ainda retém as características essenciais do objeto original. A versão afinada da forma é chamada de esqueleto. O esqueleto de uma região pode ser definido em termos da Transformação do Eixo Médio (*Medial Axis Transformation*) - MAT.

A MAT de uma região R com fronteira B é obtida da seguinte forma: para cada ponto p em R , encontra-se seu vizinho mais próximo em B . Se p tem mais de um vizinho à mesma distância mínima, diz-se que p pertence ao eixo médio (esqueleto) de R .

Os algoritmos de esqueletização excluem, de forma sucessiva, diversas camadas da extremidade (borda) de um padrão até que apenas o esqueleto permaneça. A exclusão de um ponto p dependerá dos *pixels* da vizinhança deste ponto. De acordo com o modo como se examinam os pixels, estes algoritmos podem ser classificados como iterativos ou não iterativos.

Os algoritmos de afinamento iterativos são aqueles que produzem o esqueleto através da exclusão repetitiva das características da borda do objeto. Eles podem ser subdivididos em duas categorias: seqüenciais e paralelos. Nos algoritmos seqüenciais, os pixels são examinados para exclusão em uma seqüência fixa em cada iteração, e a exclusão de p na n -ésima iteração depende de todas as operações que tenham sido realizadas até aquele momento. Por outro lado, nos algoritmos paralelos, a exclusão na n -ésima iteração depende apenas dos pixels da iteração $n-1$. Por isso, todos os pixels podem ser analisados independentemente, de forma paralela a cada iteração.

Os algoritmos de afinamento não-iterativos são aqueles que extraem o esqueleto de um objeto a partir de uma varredura na imagem. Eles produzem o esqueleto do objeto diretamente em um único passo sem examinar individualmente todos os pixels. De certa forma esses algoritmos são mais intuitivos que os métodos iterativos e geram esqueletos que conservam propriedades globais, além disso, conseguem manter a conectividade do objeto durante o processo de afinamento.

O problema para os algoritmos de afinamento é o de determinar quais pixels são redundantes em uma imagem. Por outro lado, no processo de afinamento os pixels que devem ser removidos são primeiramente marcados e, posteriormente, removidos em um segundo passo. Este processo é repetido até que não existam mais pixels redundantes, até o ponto que os pixels remanescentes são aqueles que pertencem ao esqueleto do objeto. Este método, chamado de afinamento, é caracterizado por sucessivas deleções e é um método bastante utilizado na prática. O esqueleto gerado do objeto precisa permanecer intacto e deve respeitar as seguintes propriedades:

- As regiões afinadas precisam ter um pixel de largura;
- Os pixels que formam o esqueleto precisam permanecer próximos do centro da região de cruzamento de regiões. É necessário que os pixels do esqueleto formem o mesmo número de regiões que a imagem original apresentava.

Vários métodos já foram implementados e testados, conforme pode ser observado em Plotze e Bruno (2005). No entanto, um dos métodos mais rápidos e com bons resultados para o estudo de raízes é o método *Zhang-Suen* (ZHANG e SUEN, 1984).

Método Zhang-Suen

A idéia básica do método *Zhang-Suen* é decidir se um determinado pixel será eliminado olhando somente seus oito vizinhos. Existem duas regras para decidir se o pixel deve ou não ser removido.

A primeira regra diz que o pixel somente pode ser apagado se, o número de conectividade do mesmo for igual a um. Isto significa que o pixel é conectado somente a uma única região. Se um pixel possuir o número de conectividade igual a dois, então, duas regiões conectadas poderão se separar, e isto viola a terceira propriedade de esqueletização.

A segunda regra é que o pixel somente pode ser apagado, se este tiver mais de um e menos de sete vizinhos. Esta regra assegura que os pixels resultantes foram retirados sucessivamente das bordas da região da imagem, e não de suas partes internas. Para afinar uma região estas regras devem ser aplicadas para todos os pixels que pertencem à região, e os pixels que satisfazem as condições acima podem ser removidos.

Para realizar a esqueletização de *Zhang-Suen* toma-se por base sempre a comparação do pixel que se está tentando eliminar sobre seus oito

vizinhos. Existem quatro regras que devem ser aplicadas se e somente se as quatro forem satisfeitas, o pixel poderá ser eliminado. Tais regras asseguram que se o pixel em questão for eliminado não fará com que diferentes regiões ligadas por ele passem a ficar separadas. Também assegura que a eliminação de pixels sempre ocorrerá nas bordas do objeto. A Figura 8 mostra uma imagem simulada de raízes lavadas e o resultado da esqueletização por *Zhang-Suen* com 2, 4 e 10 iterações implementadas no software SIARCS®.

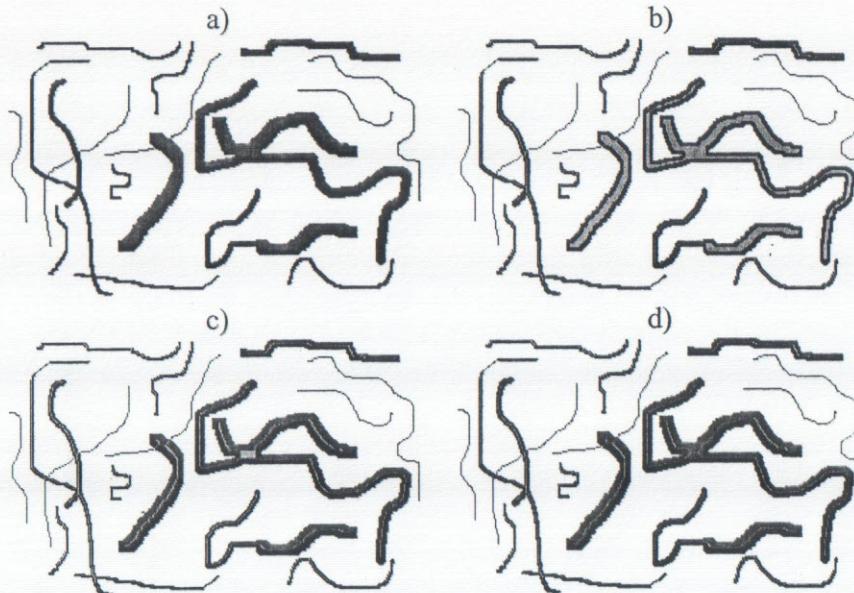


Figura 8. Imagem simulada de raízes (a) e resultados da esqueletização por *Zhang-Suen* com 2 iterações (b), 4 iterações (c) e 10 iterações (d) implementadas no software SIARCS®.

Análise

Uma vez segmentados os objetos de interesse e efetuados os processamentos básicos, a última etapa para completar o estudo através do processamento de imagens é a etapa de análise. Dentre as várias técnicas de análise conhecidas na literatura (COSTA e CÉSAR-JÚNIOR, 2001), será apresentada aqui uma análise de forma muito utilizada nas aplicações em Ciência do Solo.

Análise de forma

Existem vários algoritmos de análise de forma (COSTA e CÉSAR Jr., 2001). Neste capítulo foram destacados os descritores de formas geométricas, denominados de momentos. A teoria completa dos descritores pode ser vista na literatura básica de processamento de imagens (JAIN, 1989; GONZALEZ e WINTZ, 1987). Dada uma imagem $M \times N$, os momentos principais m_{pq} são dados por:

$$m_{pq} = \sum_{i=0}^M \sum_{j=0}^N i^p \cdot j^q \cdot f(i, j)$$

sendo $f(i, j)$ a imagem a ser analisada.

Primeiramente, efetua-se a segmentação da imagem, obtendo-se todos os pixels de interesse tendo intensidade “1”. Com isso, pode-se substituir a função acima por:

$$m_{pq} = \sum_{i \in R} \sum_{j \in R} i^p \cdot j^q \quad i, j \in R$$

sendo R a região de interesse.

A área do objeto a ser analisado é dada por:

$$AF = m_{00} = \sum_{i \in R} \sum_{j \in R} 1 \quad i, j \in R$$

A partir dos momentos principais, podem-se determinar os descritores mais utilizados para largura e comprimento. A partir destes vários outros descritores são calculados, como:

Centro de massa (x, y) de R , dado por:

$$x = (m_{10} / m_{00}); \quad y = (m_{01} / m_{00})$$

Momentos centrais, dados por:

$$\mu_{pq} = \sum_{i=0}^M \sum_{j=0}^N (i - x)^p \cdot (j - y)^q \quad i, j \in R$$

Ângulo θ entre o eixo principal e a horizontal é dado por:

$$\theta = \frac{1}{2} \tan^{-1} [2 \mu_{11} / (\mu_{20} - \mu_{02})]$$

Obtendo-se o ângulo θ , as equações dos eixos principais com inclinação θ são dadas por:

$$\alpha = x \cos \theta + y \sin \theta; \quad \beta = -x \sin \theta + y \cos \theta$$

Os valores de α_{\min} , α_{\max} , β_{\min} , β_{\max} para os pontos (x, y) de R serão as coordenadas do menor retângulo que engloba a região, sobre os eixos α , β . O comprimento C e a largura L do retângulo são:

$$C = \alpha_{\min} - \alpha_{\max}; \quad L = \beta_{\min} - \beta_{\max}$$

Estes são os valores do comprimento e largura a serem determinados. Outro fator que pode ser determinado é a excentricidade, medida pela relação entre o maior (a) e o menor (b) eixos de uma elipse. A elipse utilizada para determinar o fator de excentricidade (a/b) é aquela que melhor representa o contorno da região R e é dada por:

$$a = (4/\pi)1/4[(I_{\max})^3 / I_{\min}]^{1/8}$$

$$b = (4/\pi)1/4[(I_{\min})^3 / I_{\max}]^{1/8}$$

onde I_{\min} e I_{\max} são o menor e o maior momentos de inércia, dados por:

$$I_{\min} = \sum \sum [(j-y)\cos \theta - (i-x)\sin \theta]^2 \quad i, j \in R$$

$$I_{\max} = \sum \sum [(j-y)\sin \theta + (i-x)\cos \theta]^2 \quad i, j \in R$$

A razão a/b é um bom descritor de excentricidade do objeto em estudo.

Morfologia matemática

A morfologia matemática (MM) é uma boa opção de ferramenta de processamento de imagens para lidar com problemas em Ciência do Solo, Sensoriamento Remoto e em diversos outros campos. Apesar da diversidade de objetivos existentes nessas áreas, todos esses problemas têm uma característica em comum: a necessidade de extraír informações de imagens.

A utilização da morfologia matemática na área de Processamento Digital de Imagens foi inicialmente proposta por Georges Matheron e Jean Serra, e consiste no estudo da forma, isto é, o estudo da estrutura geométrica de entidades presentes em uma imagem (SERRA, 1982; FACON, 1996). O seu objetivo é extraír informações relativas à geometria e à topologia de um conjunto desconhecido de uma imagem. A grande chave da morfologia matemática é o elemento estruturante. O elemento estruturante é um conjunto cuja forma e tamanho são conhecidos. Esse elemento é comparado, a partir de uma transformação, ao conjunto desconhecido da imagem. O seu formato e seu tamanho possibilitam testar e quantificar de que maneira o elemento estruturante “está ou não

está contido” na imagem. Marcando-se, na imagem resultante, as posições onde o elemento estruturante inclui-se na imagem original, obtém-se uma primeira resposta sobre a estrutura geométrica das entidades presentes na imagem.

A morfologia matemática representa um ramo do processamento não linear e permite processar imagens com objetivos de realce, de segmentação, de detecção de bordas, de esqueletização, de afinamento, de análise de formas, dentre outros. Os conceitos introduzidos aqui são estabelecidos para imagens binárias, mas podem ser estendidos também para imagens em tons de cinza e coloridas (FACON, 1996). Ao contrário de outras técnicas de processamento de imagens, a morfologia matemática não requer cálculos matemáticos complexos, dispensa a fase de treinamento e não necessita de determinação de parâmetros, como é o caso das redes neurais, contornos ativos e algoritmos genéticos, respectivamente.

Operadores Morfológicos

Em imagens binárias, os conjuntos em questão são membros do espaço inteiro bidimensional Z^2 , onde cada elemento do conjunto é um vetor 2D cujas coordenadas são as coordenadas (x, y) do pixel preto (por convenção) na imagem. Imagens com mais níveis de cinza podem ser representadas por conjuntos cujos elementos estão no espaço Z^3 . Neste caso, os vetores têm três elementos, sendo os dois primeiros as coordenadas do pixel e o terceiro seu nível de cinza.

Dilatação e erosão binárias

As operações morfológicas básicas são dilatação e erosão. Para bem compreendê-las, são apresentadas a seguir algumas definições úteis da teoria de conjuntos.

Sejam A e B conjuntos em Z^2 , cujos componentes são $a = (a_1, a_2)$ e $b = (b_1, b_2)$, respectivamente. A translação de A por $x = (x_1, x_2)$, denotada por $(A)_x$, é definida como:

$$(A)_x = \{c \mid c = a + x, \text{ para } a \in A\}$$

A reflexão de B , denotada por \hat{B} , é definida como:

$$\hat{B} = \{x \mid x = -b, \text{ para } b \in B\}$$

O complemento do conjunto A é: $A^c = \{x \mid x \notin A\}$

Finalmente, a diferença entre dois conjuntos A e B , denotada por $A - B$, é definida como:

$$A - B = \{x \mid x \in A, x \notin B\} = A \cap B^c$$

A Figura 9 ilustra geometricamente as definições apresentadas, onde os pontos pretos identificam a origem do par de coordenadas. A Figura 9a mostra o conjunto A . A parte (b) mostra a translação de A por $x = (x_1, x_2)$. O conjunto B é exibido na parte (c), enquanto (d) mostra sua reflexão em relação à origem. Finalmente, a parte (e) apresenta o conjunto A e seu complemento, enquanto a Figura 9f mostra a diferença entre este conjunto A e o conjunto B .

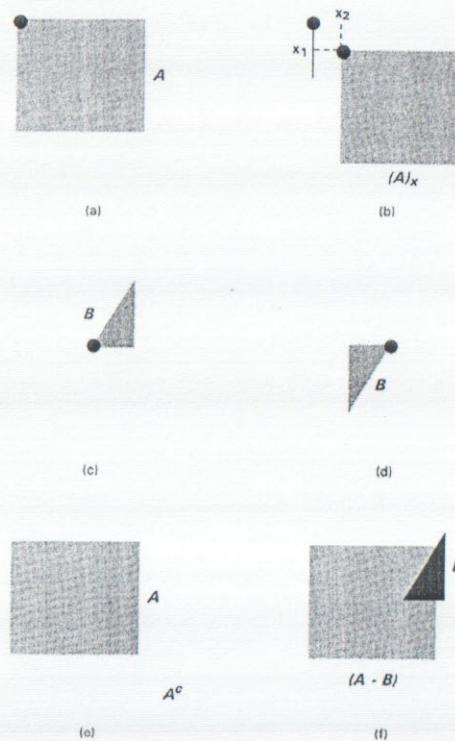


Figura 9. Exemplos de operações básicas sobre conjuntos

Dilatação

Sejam A e B conjuntos no espaço Z^2 e seja ϕ o conjunto vazio. A dilatação de A por B , denotada por $A \oplus B$, é definida como:

$$A \oplus B = \{x \mid (\hat{B})_x \cap A \neq \emptyset\}$$

Portanto, o processo de dilatação consiste em obter a reflexão de B sobre sua origem e depois deslocar esta reflexão x . A dilatação de A por B é, então, o conjunto de todos os x deslocamentos para os quais a interseção de $(\hat{B})_x$ e A inclui pelo menos um elemento diferente de zero. Com base nesta interpretação, a equação anterior pode ser escrita como:

$$A \oplus B = \{x \mid [(\hat{B})_x \cap A] \subseteq A\}$$

O conjunto B é o elemento estruturante. A Figura 10 mostra os efeitos da dilatação de um conjunto A usando três elementos estruturantes (B) distintos. Observar que as operações morfológicas são sempre referenciadas a um elemento do conjunto estruturante (neste caso, o elemento central).

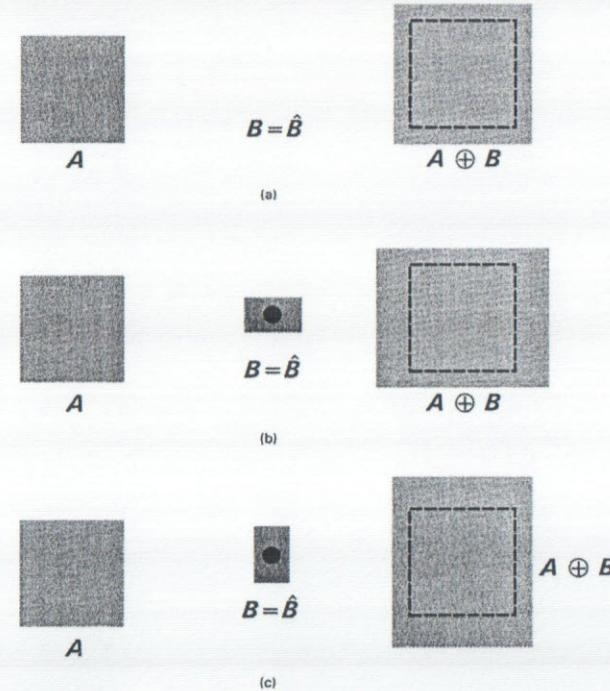


Figura 10. Dilatação.

Erosão

Sejam A e B conjuntos no espaço \mathbb{Z}^2 . A erosão de A por B , denotada por $A \Theta B$, é definida como: $A \Theta B = \{x \mid (B)_x \subseteq A\}$

O que, em outras palavras significa dizer que a erosão de A por B resulta no conjunto de pontos x tais que B , transladado de x , está contido em A . A Figura 11 mostra os efeitos da erosão de um conjunto A usando três elementos estruturantes (B) distintos. A dilatação e a erosão são operações duais entre si com respeito a complementação e reflexão.

Ou seja: $(A \ominus B)^c = A^c \oplus \hat{B}$

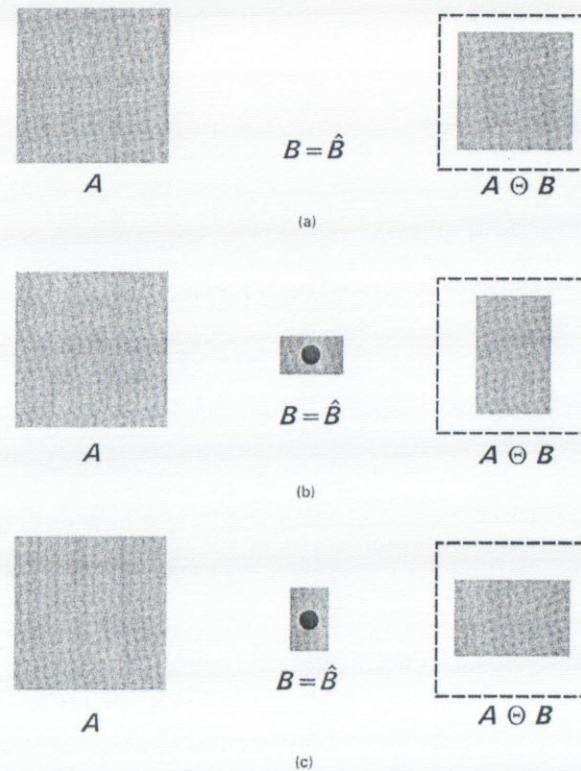


Figura 11. Erosão.

Abertura e fechamento binário

Como observado nas figuras da seção anterior, a dilatação expande uma imagem, enquanto a erosão a encolhe. Nesta seção são apresentadas duas outras importantes operações morfológicas: a abertura e o fechamento.

A abertura, em geral, suaviza o contorno de uma imagem, quebra istmos estreitos e elimina proeminências delgadas. O fechamento, por sua vez, funde pequenas quebras e alarga golfos estreitos, elimina pequenos orifícios e preenche *gaps* no contorno. A abertura de um conjunto A por

um elemento estruturante B , denotada por $A \circ B$, é definido como:

$$A \circ B = (A \ominus B) \oplus B$$

Isso equivale a dizer que a abertura de A por B é simplesmente a erosão de A por B seguida de uma dilatação do resultado por B .

O fechamento do conjunto A pelo elemento estruturante B , denotado por $A \bullet B$, é definido como:

$$A \bullet B = (A \oplus B) \ominus B$$

Isso nada mais é que a dilatação de A por B seguida da erosão do resultado pelo mesmo elemento estruturante B .

A Figura 12 mostra um exemplo de operação de abertura, enquanto a Figura 13 mostra um exemplo de operação de fechamento. Ambas utilizam um elemento estruturante circular. A Figura 12 mostra a operação de abertura, indicando no alto o conjunto original A , na linha intermediária, a etapa de erosão e na linha inferior, o resultado da operação de dilatação aplicada ao conjunto resultante da erosão.

Na Figura 13 são detalhadas as operações de dilatação do conjunto original A e subsequente erosão do resultado.

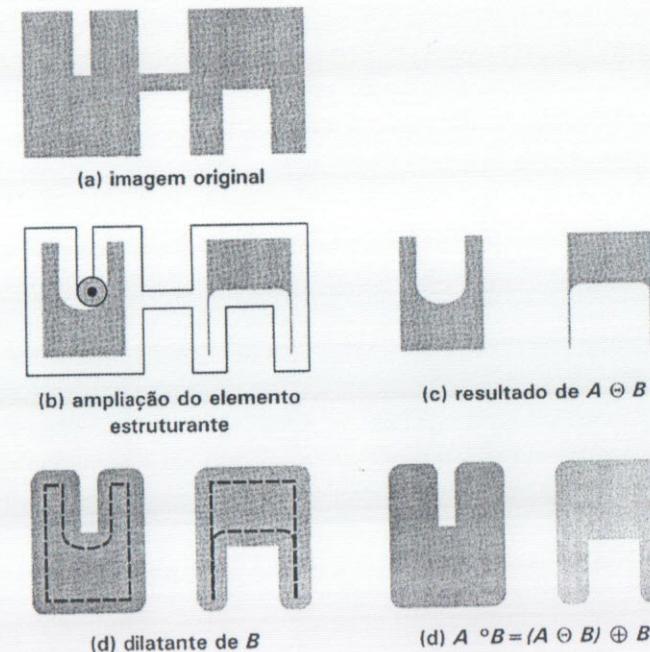


Figura 12. Exemplo de abertura.

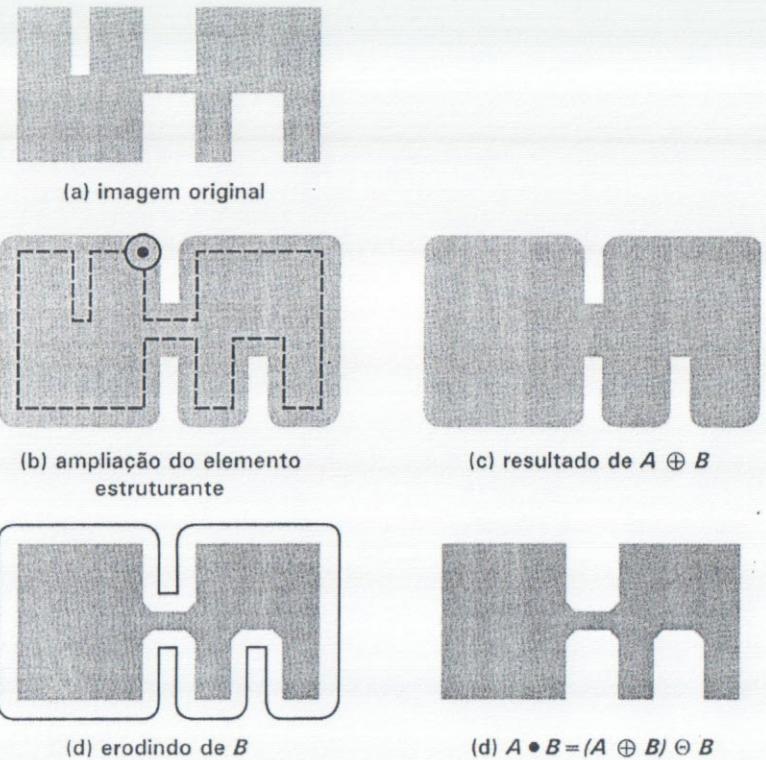


Figura 13. Exemplo de fechamento.

Interpretação geométrica da abertura e do fechamento

A abertura e o fechamento podem ser interpretados geometricamente de maneira simples. Suponha-se, por exemplo, o elemento estruturante circular B da Figura 12 como um disco plano. A fronteira de $A \circ B$ é composta pelos pontos da fronteira de B , que se distanciam mais para dentro da fronteira de A , à medida que B é girado em torno da parte interna desta fronteira. Esta propriedade geométrica de “encaixe” da operação de abertura pode ser expressa em termos da teoria de conjuntos como:

$$A \circ B = \bigcup \{(B)_x \mid (B)_x \subset A\}$$

A Figura 14 mostra este conceito com um elemento estruturante de outro formato. De maneira similar, a operação de fechamento pode ser interpretada geometricamente, supondo que o disco desliza pela parte externa da fronteira de A . Geometricamente, um ponto z é um elemento

de $A \bullet B$ se e somente se $(B)_x \cap A \neq \emptyset$ para qualquer translação de (B) que contenha z . A Figura 15 mostra esta propriedade.

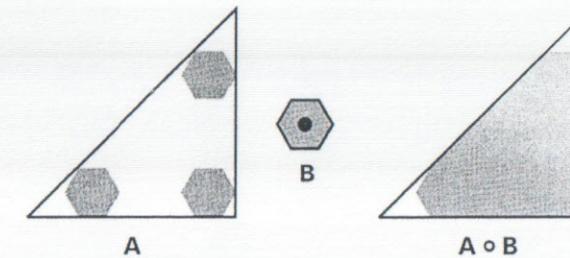


Figura 14. Propriedade de ‘encaixe’ da abertura.

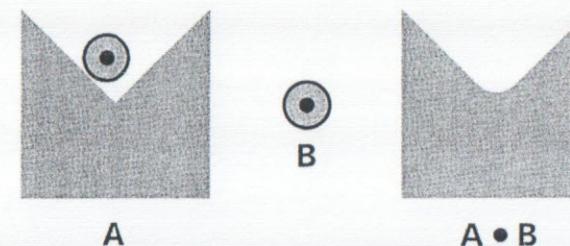


Figura 15. Interpretação geométrica do fechamento.

Assim como no caso da dilatação e erosão, a abertura e o fechamento são duais, ou seja:

$$(A \bullet B)^c = (A \circ \hat{B})$$

As propriedades de abertura são:

- $A \circ B$ é um subconjunto (subimagem) de A ;
- Se C é um subconjunto de D , então $C \circ B$ é um subconjunto de $D \circ B$;
- $(A \circ B) \circ B = A \circ B$.

As propriedades de fechamento são:

- A é um subconjunto $A \bullet B$;
- Se C é um subconjunto de D , então $C \bullet B$ é um subconjunto de $D \bullet B$;
- $(A \bullet B) \bullet B = A \bullet B$.

Estas propriedades auxiliam na interpretação dos resultados obtidos,

quando as operações de abertura e fechamento são utilizadas para construir filtros morfológicos. Convém observar que o sucesso de tal técnica depende do elemento estruturante ser maior que o maior aglomerado de pixels ruidosos conectados presente na imagem original.

Operadores básicos em níveis de cinza

Seja Z o conjunto dos inteiros, seja E um retângulo em Z^2 representando um subconjunto da grade quadrada e seja K um intervalo $[0, k]$ de Z com $k > 0$. A coleção de funções de E em K representará as imagens nível-de-cinza de interesse. Representa-se tal coleção por KE e por f um elemento genérico de K^E .

Seja B um subconjunto de Z^2 , chamado de elemento estruturante. Representa-se por $B + h$ a translação de B por qualquer vetor h em Z^2 :

$$B + h = \{x + h \mid x \in B\}$$

Representa-se por B' o transposto de B , isto é,

$$B' = \{-x \mid x \in B\}$$

Seja g uma função estruturante definida a partir de $B \subset E \oplus E'$. A dilatação de f por g é a função $\delta_g(f)$ em KE , que, para qualquer x em E , dada por:

$$\delta_g(f)(x) = \max \{f(y) + g(y - x) \mid y \in (B' + x) \cap E\}$$

e a erosão de f por g é a função $\varepsilon_g(f)$ em KE , dada por, para qualquer x em E :

$$\varepsilon_g(f)(x) = \min \{f(y) - g(y - x) \mid y \in (B' + x) \cap E\}$$

A abertura morfológica é dada por uma erosão seguida de uma dilatação:

$$\gamma_g(f) = \delta_g \varepsilon_g(f)$$

Processamentos morfológicos

Reconstrução binária

O processo de reconstrução consiste em recuperar um conjunto S a partir de um conjunto Z , onde S é um subconjunto de uma imagem binária X , e

Z é uma amostra de S . Pode-se dizer que S é marcado por Z , que é denominado marcador.

A reconstrução binária $\rho_S(Z)$ de uma máscara (conjunto finito) S , a partir do marcador Z ($Z \subseteq S$), usando o elemento estruturante B , é dada por:

$$\rho_s(Z) = \lim_{n \rightarrow \infty} \underbrace{\delta_{cs}^B \dots \delta_{cs}^B}_{n} (Z)$$

onde $\delta_{cs}^B(\dots \delta_{cs}^B(Z))$ representa a dilatação condicional de Z relativamente a S .

A reconstrução permite eliminar os padrões indesejáveis sem deformar os desejáveis e é utilizada na aplicação de estudo granulométrico do solo.

Granulometria binária

A contagem e a medição de partículas e agregados de um dado solo são úteis a engenheiros, geólogos, agrônomos e biólogos pois, por meio da determinação de freqüências de tamanhos de partículas, presentes em amostras, é possível conhecer suas propriedades ou classificar.

Para rochas, a contagem e a medição de grãos é feita através de peneiras, ou seja, fisicamente. Pela contagem ou pesagem dos materiais retidos na peneira é estabelecido um histograma que relaciona o tamanho do grão com a quantidade de material.

Este histograma é chamado de curva granulométrica. Assim, uma definição adequada do tamanho do grão presente no material depende da escolha do conjunto e do tamanho de malhas de peneiras usadas.

Existem diferentes formas de representação das curvas granulométricas em função do tamanho das peneiras: por número ou por medidas (peso ou volume). No primeiro caso, a cada partícula é atribuído o mesmo valor, independente de sua massa, ou tamanho. No segundo caso, a cada partícula é atribuído um valor proporcional à medida considerada. Esses dois tipos de granulometrias algumas vezes são relacionáveis.

Com as ferramentas de Morfologia Matemática é possível caracterizar tamanhos de objetos presentes na imagem, mais precisamente por meio de curvas granulométricas.

Sua aplicação em imagens binárias ficou conhecida como granulometria binária (SERRA, 1982). Ferramentas granulométricas podem ser empregadas também na análise de imagens nível de cinza, mas seu

emprego não tem sido tão amplo quanto no caso binário. Um exemplo pode ser visto em Trettel et al. (1996).

A granulometria pode ser comparada com um processo de peneiramento. Peneirar consiste em separar substâncias reduzidas ao estado de fragmento, que apresentam vários tamanhos. Efetuar um bom peneiramento depende do tamanho da malha da peneira usada. Após o peneiramento, obtém-se dois conteúdos: o primeiro com os objetos menores que a malha da peneira, o segundo com o que sobrou do peneiramento, de tamanho maior que a malha.

O conceito de granulometria, como estabelecido por Matheron (1975), está baseado na seguinte definição:

Seja $\Phi = (\phi_\lambda)_{\lambda > 0}$ uma família de transformações de imagem dependendo de um único parâmetro λ . Esta família constitui uma granulometria se e somente as seguintes propriedades são satisfeitas:

- $\forall \lambda \geq 0, A \subset B \Rightarrow \phi_\lambda(A) \subset \phi_\lambda(B)$, (ϕ_λ é crescente)
- $\forall \lambda \geq 0, \phi_\lambda(A) \subset A$, (ϕ_λ é anti-extensiva)
- $\forall \lambda, \mu \geq 0, \phi_\lambda[\phi_\mu(A)] = \phi_\mu[\phi_\lambda(A)] = \phi_{\max(\lambda, \mu)}(A)$, (propriedade do crivo mais forte)

Pode-se mostrar que estas três propriedades, conhecidas como axiomas de Matheron, são satisfeitas pela definição das aberturas morfológicas. Conseqüentemente, uma família de aberturas $[\Phi_g(f) = \gamma_g(f)]$, baseada em qualquer conjunto convexo B , constitui uma granulometria.

Definindo-se uma função m que mede $\Phi_g(f)$ de alguma maneira (área para imagens binárias, volume para nível-de-cinza, etc), o histograma gerado aumentando-se g pode ser visto como uma assinatura de f para aquela escolha particular de g , que fornece então uma curva granulométrica, freqüentemente referida como Espectro de Padrões de f , $PS\phi(f)$:

$$PS\phi(f)(n) = m(\phi_n(f)) - m(\phi_{n-1}(f))$$

A família de granulometrias $\phi_n(f)$, conforme indicado acima, é dada pelas aberturas morfológicas de f por uma função estruturante g . A granulometria por abertura pode gerar deformações nos conjuntos, o que resulta em função e densidade de distribuições incorretas dificultando, portanto, a interpretação. Isto ocorre porque os conjuntos podem ter

diversas formas, ou seja, a imagem contém vários padrões e/ou ruídos, dificultando o processo de peneiramento.

Peneirar, por exemplo, estruturas redondas e alongadas a partir de uma única seqüência de elementos estruturantes pode resultar em resultados duvidosos. Conjuntos sobrepostos podem gerar o mesmo efeito. Várias soluções são possíveis. Uma delas é modificar o processo de peneiramento por abertura, introduzindo o processo de reconstrução binária a partir de marcadores binários. Sabe-se que, após a abertura, o conjunto que “sobrevive” existe realmente na peneira. Somente a sua forma e as suas dimensões foram alteradas. A idéia consiste, portanto, em extraír o marcador de cada conjunto restante (por exemplo, pelo processo de última erosão) para depois reconstruir o verdadeiro conjunto que normalmente deveria aparecer.

Afinamento (Thinning) morfológico

O afinamento de um conjunto A por um elemento estruturante B , denotado $A \otimes B$, pode ser definido com a ajuda de uma seqüência de elementos estruturantes:

$$\{B\} = \{B^1, B^2, B^3, \dots, B^n\}$$

onde B^1 é uma versão rotacionada de B^{i-1} . Usando este conceito, define-se o afinamento por uma seqüência de elementos estruturantes como:

$$A \otimes \{B\} = ((\dots((A \otimes B^1) \otimes B^2) \dots) \otimes B^n)$$

Em outras palavras, o processo consiste em afinar A por um passo com B^1 , então afinar o resultado com um passo de B^2 e, assim sucessivamente até que A seja afinado com um passo de B^n . O processo todo é repetido até que não ocorram outras mudanças.

A Figura 16 mostra todas as etapas de afinamento de uma imagem, usando oito elementos estruturantes, indicados no alto da figura. A partir do conjunto original A , são ilustrados os resultados parciais mais relevantes até a situação em que nenhum elemento estruturante consiga remover nenhum outro pixel da imagem.

Como este resultado ainda possui conexões diagonais redundantes entre pixels pretos, estas são removidas, utilizando o conceito de m conectividade. Note que nesta figura, todos os pixels, não representados explicitamente, podem ser considerados brancos e que os números dentro de cada pixel, indicam o elemento estruturante utilizado e não iteração.

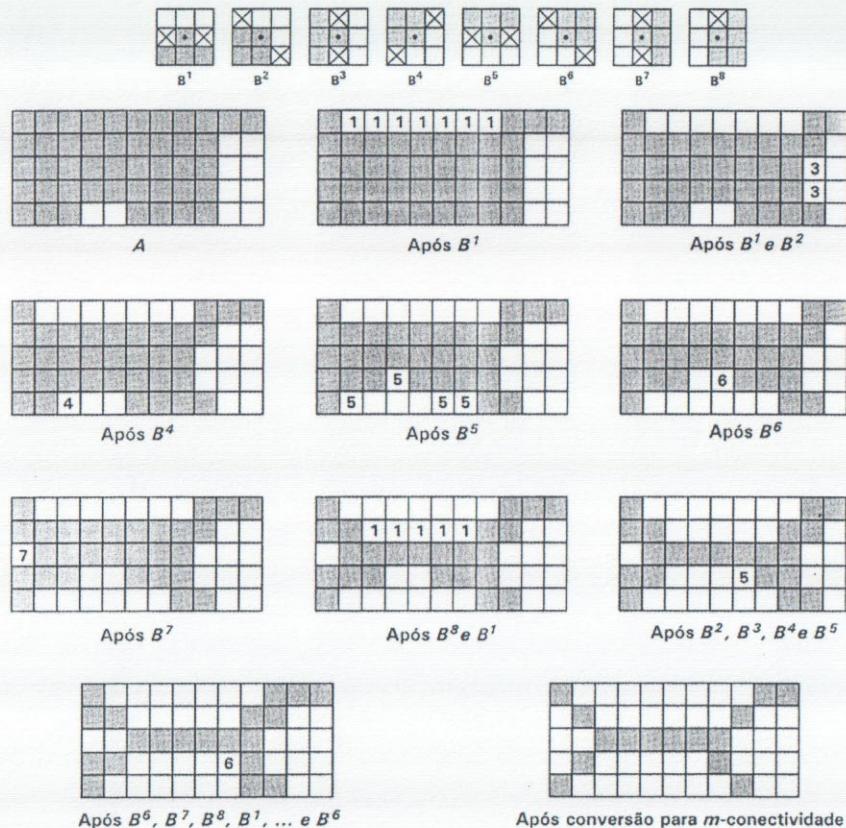


Figura 16. Afinamento (Thinning).

Transformada de distância

Um dos objetivos de reconhecimento de formas binárias é imitar a habilidade humana em se reconhecer uma variedade de formas em uma imagem. Uma dessas técnicas pode ser o cálculo da função distância que pode ajudar a identificar subconjuntos em conjuntos complexos. No caso do estudo de raízes, é utilizada para caracterização de classes de diâmetros das raízes.

Partido da definição da erosão em nível de cinza:

$$\varepsilon_g(f)(x) = \min\{f(y) - g(y-x) \mid y \in (B+x) \cap E\}$$

Para cada pixel p , a Transformada de Distância (TD) representa a distância do pixel p ao fundo, dada por:

$$TD_g(f)(x) = \min\{n \in N \mid p \notin \varepsilon_ng(f)(x)\}$$

O algoritmo para uma abordagem morfológica da função distância de uma imagem binária foi definida em Facon (1996), da seguinte forma:

- Uma nova imagem X é criada onde os pixels pretos da imagem binária X são alterados com um valor "infinito" (qualquer valor maior que a maior distância) e os pixels brancos da imagem (correspondentes ao fundo) são alterados com o valor 0.
- A nova imagem X é rastreada de duas maneiras, a primeira da esquerda para direita de cima para baixo, e a segunda da direita para esquerda de baixo para cima.
- A Função Distância é determinada por erosão em níveis de cinza de X .
- A erosão pode ser realizada com qualquer elemento estruturante, que será dividido em duas "metades" para acelerar o processo. A primeira "metade" $E1$ do elemento estruturante vai de seu primeiro ponto superior esquerdo até o seu centro não incluído. A segunda "metade" $E2$ começa imediatamente depois do centro 2 do elemento estruturante até o seu último ponto inferior direito. Desse modo, a primeira parte do rastreamento é realizar a erosão na imagem com o $E1$ e depois com o $E2$ como descrito anteriormente.

Um exemplo do mapa de distâncias pode ser visto da Figura 17.

a) b)



Figura 17. Imagem binária (a) e a transformada de distância (b).

Aplicação do processamento de imagens no estudo do sistema radicular

As raízes possuem um papel fundamental para o solo, promovendo formação dos agregados durante o crescimento, aproximando partículas minerais pelas pressões exercidas no seu avanço através do espaço poroso do solo, extração de água e liberação de substâncias orgânicas

para a rizosfera. Tudo isso se deve ao fato da rizosfera ser rica em energia, oriunda de sua associação com as plantas. Sendo assim, o estudo das raízes tem grande importância para melhor compreensão das relações solo–planta (MIELNICZUK, 1999).

Há muito se sabe que o estudo do desenvolvimento das raízes, sua distribuição, extensão e atividade são de extrema importância para o entendimento da produção agrícola, bem como das alterações provocadas no solo e na planta pelos manejos físico e químico do solo e pelas condições naturais (PEARSON, 1974). As pesquisas sobre a interação solo–raiz vêm se intensificando e tem-se buscado sistemas radiculares mais profundos, que possibilitem à cultura resistir melhor a períodos de seca e aumentar a produção (SUMMER, 1992).

A compactação do solo, provocada pela intensificação da mecanização agrícola, aliada ao manejo inadequado do solo, também tem proporcionado maior preocupação com o ambiente radicular (SALATA et al., 1987; MERTEN e MIELNICZUK, 1991; MEDINA, 1993). Além disso, o conhecimento da profundidade efetiva do sistema radicular é um importante parâmetro utilizado nos cálculos de irrigação (KOFFLER, 1986), bem como nos modelos matemáticos criados para prever a absorção de água e nutrientes pelas plantas.

De forma geral, a avaliação de raízes, a campo, tem sido efetuada de duas maneiras: diretamente no perfil de solo ou através de raízes lavadas (BOHM, 1979), levando em conta o custo, a precisão e o tempo de análise. A coleta de informações no campo é uma tarefa bastante árdua e é feita de diferentes formas: método do monólito, do trado, da parede do perfil, parede de vidro, dentre outros.

Em Böhm (1979), são descritos os métodos clássicos de análise de raízes demonstrando que as dificuldades são de natureza metodológica, já que as técnicas existentes são tediosas, demoradas e apresentam, com certa freqüência, uma exatidão que é considerada insatisfatória. Porém, muitas metodologias vêm sendo desenvolvidas para facilitar os estudos de raízes, levando em conta custo, precisão e tempo de análise. As técnicas baseadas em processamento de imagens têm se destacado na literatura para análise de raízes (JORGE e CRESTANA, 1996).

Principais métodos utilizados para coleta de informações de raízes

A escolha do método depende, entre outros, do objetivo do estudo, da facilidade na coleta dos dados e da disponibilidade de recursos. De forma

geral, as avaliações têm sido efetuadas de duas maneiras: diretamente no perfil do solo ou através de raízes lavadas (BOHM, 1979). Em ambos, aplica-se perfeitamente o processamento de imagens como uma das formas de aumentar a precisão e tempo de análise.

Métodos de raízes lavadas

Um dos métodos mais utilizados para o estudo de raízes é o método do monólito, ou seja, a retirada de um monólito de solo e a separação de raízes por lavagem. Mesmo sendo um método padrão, existem algumas variações do método, tais como: placa de pregos, anéis volumétricos, etc. Entre estas, o método com placa de pregos se destaca como referência no estudo de raízes (IVO, 1999).

Por meio deste método, uma amostra representativa do sistema radicular é retirada através do uso de uma prancha especial, a qual, através dos pregos que possui, permite a permanência das raízes em posições próximas às suas posições naturais, mesmo após o procedimento da lavagem da amostra.

Uma vez retirada a placa com pregos, faz-se o processo de lavagem, onde se consome muito tempo. Porém, para facilitar o trabalho, as amostras devem ser imersas em recipientes com água e dependendo da textura do solo, adiciona-se também um dispersante, por 12 a 24 horas. Depois da saturação, o solo é retirado com o auxílio de um jato de água sob baixa pressão, de baixo para cima da placa evitando a perda de raízes. Na Figura 18 apresenta-se uma placa com pregos depois de lavada.

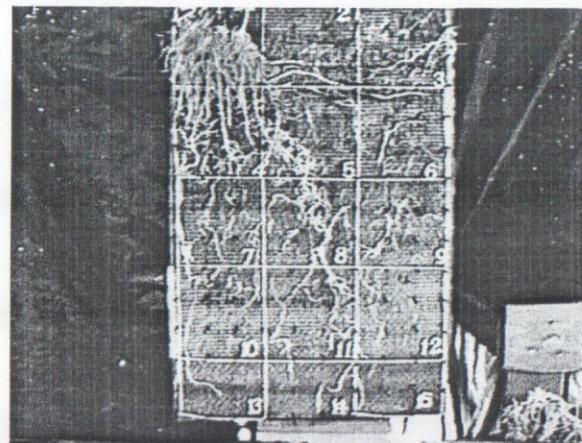


Figura 18. Perfil da placa com pregos depois de lavada.

Apesar deste método ser trabalhoso e consumir muito tempo, ele é sempre utilizado como um método padrão, pois a partir dele, é possível fazer um estudo tanto qualitativo como quantitativo das raízes e além disso, segundo Köpke (1981), entre os métodos do monólito, este é o que possui maior exatidão dos resultados.

Outro variante bastante utilizado é feito com o auxílio de um tubo de PVC ou acrílico, com diâmetro e comprimento variável para retirar um monólito cilíndrico do solo. No entanto, as dimensões máximas que têm sido utilizadas para o estudo de raízes são de 1 m de comprimento por 0,10 m de diâmetro interno.

A penetração do tubo no solo é feita utilizando macaco hidráulico. Para que seja possível a penetração do tubo no solo é necessário acoplar à base do mesmo, uma sapata de aço inoxidável chanfrada, que permitirá o corte das raízes, facilitando, desta forma, a sua penetração no solo (CINTRA, 1999). A coluna de solo coletada poderá ser subdividida em amostras menores, a depender da distribuição das raízes em profundidade, permitindo, dessa forma, maior mobilidade na utilização dos dados.

Depois de coletadas, as raízes são separadas do solo por processo de lavagem. A análise das raízes, propriamente dita, pode ser efetuada por processamentos de imagens específicos para raízes lavadas, utilizados nos softwares SIARCS (JORGE, 1996) e Winrhizo (ARSENAL et al., 1995). Estes processamentos específicos permitem a quantificação de raízes lavadas, de forma muita menos trabalhosa, rápida e detalhada, viabilizando o estudo da distribuição do sistema radicular no tempo e no espaço, bem como um maior número de repetições experimentais.

Métodos do perfil de solo

Este método pode também ser denominado de Método da Trincheira (JORGE, 1996) e fundamenta-se na abertura de trincheiras para melhor visualização e avaliação da distribuição das raízes da planta em estudo. A avaliação da distribuição de raízes *in situ*, consiste em cavar uma trincheira ao lado da planta e remover uma fina camada da parede do perfil, de modo a expor as raízes, que depois são contadas e registradas em desenhos ou tabelas (BOHM, 1979). Uma variação do método tem sido utilizada para análise a partir de imagens digitais (JORGE, 1996).

Para cada tipo de cultura é definida uma condição para abertura de trincheira: posição, comprimento, largura e profundidade. (JORGE et al., 1996; JORGE, 1999; MEDINA, 1999). O estudo do perfil de raízes

fornecce informações com bom nível de precisão a serem incorporadas ao sistema de produção agrícola, sendo algumas destas citadas a seguir:

- Cultivares recomendados: parâmetros de comportamento, desenvolvimento e densidade de raízes na rizosfera de cultivares a serem lançados no mercado;
- Tecnologia de cultivo: avaliações do perfil de enraizamento de diferentes cultivares ou espécies sob condições diferenciadas de sistemas de manejo do solo;
- Compactação: avaliação e diagnóstico do desenvolvimento radicular sob condições de solo compactado, correlacionando o comportamento da distribuição de raízes no perfil em função da profundidade de ocorrência, da compactação generalizada horizontal e do estado estrutural compactado com presença de fissuras;
- Interface solo–raiz: possibilidade de se obter uma visão morfológica do perfil do solo através de densidade, morfologia, diâmetro, ramificações, disposição e orientação das raízes;
- Sistema de semeadura direta: avaliação mais criteriosa do desenvolvimento radicular através de fissuras e bioporos, tipos de vazios que podem propiciar colonização radicular satisfatória no perfil do solo sob semeadura direta, mesmo com a ocorrência, neste sistema, de elevados valores de densidade do solo na camada mais superficial; e
- Fatores edáficos: com os dados do perfil de enraizamento analisados, tem-se uma comparação destes com os parâmetros físicos, químicos e biológicos do solo.

Para obtenção dos dados, pode ser feita uma contagem a partir da exposição das raízes na tela reticulada. Uma outra variação é a anotação da presença ou da ausência das raízes, utilizando a mesma tela. Outra forma é a análise de imagens a partir de imagens tiradas do perfil de solo com raízes (JORGE et al., 1999).

O método de avaliação depende do objetivo proposto. Quando se deseja saber os efeitos do manejo do solo, é suficiente a avaliação da distribuição das raízes no perfil pelas anotações de presença ou ausência. Quando se busca avaliar o efeito de determinados tratamentos no desenvolvimento das plantas ou no sistema radicular, a técnica da contagem é a mais recomendada. Pode-se, ainda, atribuir notas às raízes, classificando-as conforme os diferentes tamanhos encontrados. Ainda no campo, são encontradas anotações como: tipo, diâmetro, disposição,

orientação e localização das raízes no perfil do solo. E a forma mais fácil de eliminar a subjetividade encontrada nestas análises e melhorar a precisão é através do processamento de imagens, conforme relata Jorge (1999), quando descreve o SIARCS®, metodologia para análise de raízes em perfil do solo por processamento de imagens. A partir de imagens digitalizadas dos perfis pode-se determinar o comprimento, a distribuição e a área ocupada pelas raízes (CRESTANA et al., 1994; GUIMARÃES et al., 1996; JORGE e CRESTANA, 1996). Na Figura 19, pode-se observar um perfil de solo para a análise de raízes por processamento de imagens.

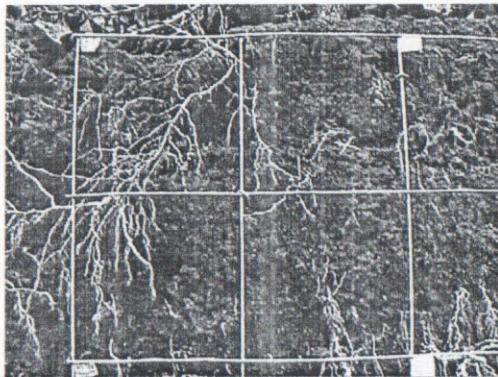


Figura 19. Imagem típica de um perfil de solo com raízes.

Técnicas de imagens digitais na avaliação de raízes

Os métodos para análise, tanto de raízes lavadas como de perfil de solo. seguem o fluxograma apresentado na Figura 20.

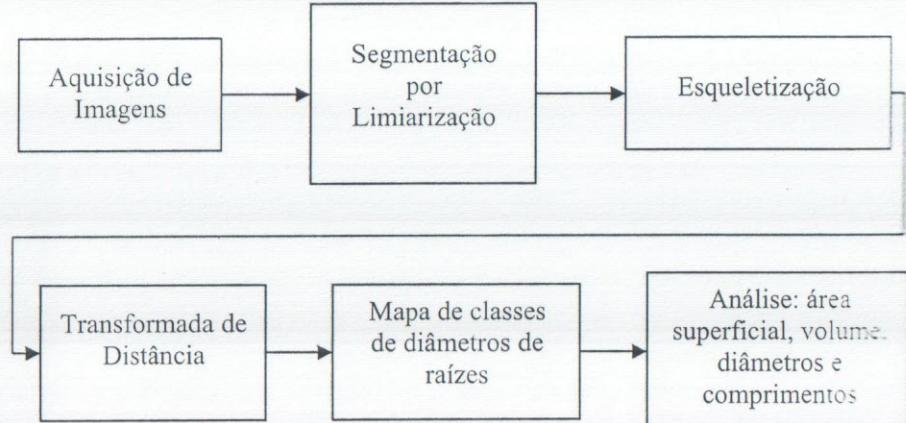


Figura 20. Passos de processamento de imagens para análise de raízes.

A obtenção das imagens de raízes deve seguir as recomendações de Jorge (1996), passando então para o processo de segmentação da imagem para separar as raízes do fundo, achar o esqueleto das mesmas e aplicar a transformada de distância.

Com o mapa de distâncias e o esqueleto gera-se o mapa de classes de diâmetros e a posterior análise através dos cálculos dos parâmetros de interesse, ou seja, comprimento, área superficial, volume e diâmetros médios ponderados.

Análise de raízes lavadas

A aquisição de imagens de raízes lavadas para avaliação através do SIARCS® é feita a partir de amostras coletadas pelos diferentes métodos, monólito, trado, placa com pregos etc. (JORGE, 1996). Todos estes passam pelo processo de aquisição de uma amostra de solo com raízes para posterior separação.

Depois de segmentada a imagem de raízes pelos métodos de limiarização, sendo o mais usual, a limiarização de Otsu já descrita, determina-se o esqueleto da imagem e a transformada de distância. A informação dada pela transformada de distância é o mapa de classes de diâmetros de raízes e que pode ser separado e visualizado segundo o esqueleto gerado.

Para melhor entendimento é apresentado um exemplo na Figura 21. Neste, a imagem típica de raízes lavadas (a) é processada gerando o esqueleto sobre as raízes. O esqueleto é colorido segundo a classe de diâmetros determinada na transformada de distância (b) e (c). As classes de diâmetros podem ser visualizadas em forma de histograma de freqüência (d).

A partir das classes de diâmetros, efetua-se o cálculo de comprimento de raízes por faixa de diâmetro. Considerando a raiz como sendo um modelo cilíndrico, pode-se calcular facilmente a área superficial das raízes pelo cálculo da área da superfície de um cilindro, com comprimento e diâmetros conhecidos.

Para cada classe de diâmetro, também é possível calcular os valores totais ou médios ponderados. Da mesma forma, se calcula o volume, que é dado pelo volume de um cilindro.

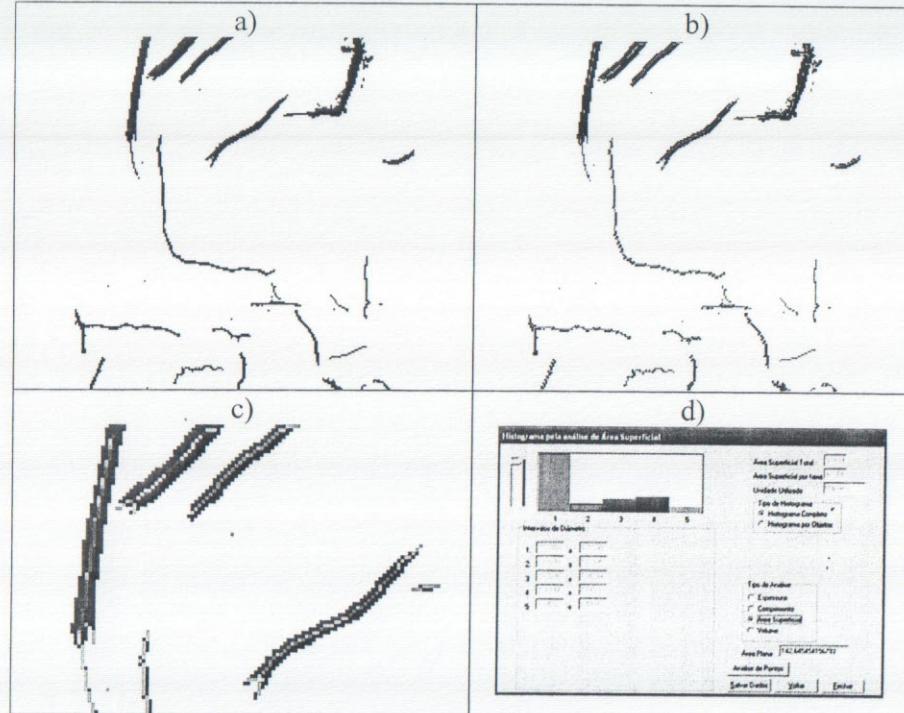


Figura 21. Imagem de raiz binarizada (a), o esqueleto classificado pela transformada de distância (b) e com zoom (c) e o (d) histograma de freqüências das classes de diâmetros.

Análise de raízes em perfil do solo

Da mesma forma que para raízes lavadas, efetua-se a segmentação das imagens, o cálculo do esqueleto, a transformada de distância e a análise. O diferencial é a segmentação, que neste caso não se deve aplicar o método de Otsu, por apresentar muitos problemas devido à variação de padrão de cor e condições de preparo do perfil de solo.

Para análise do perfil, é muito importante o cuidado na aquisição da imagem, conforme descrito por Jorge (1996; 1999).

A limiarização manual complementada de operações de retoque manual na imagem ainda é a melhor forma para segmentação das imagens, conforme proposto no sistema SIARCS® (EMBRAPA, 1996). Porém, para perfis bem preparados e com bom contraste, várias outras técnicas de segmentação por cor podem ser utilizadas.

Na Figura 22, podem ser observados os resultados da segmentação através do SIARCS 3.0 para o perfil da Figura 19. Neste caso, tem-se apenas a determinação de comprimento a partir do esqueleto da imagem.

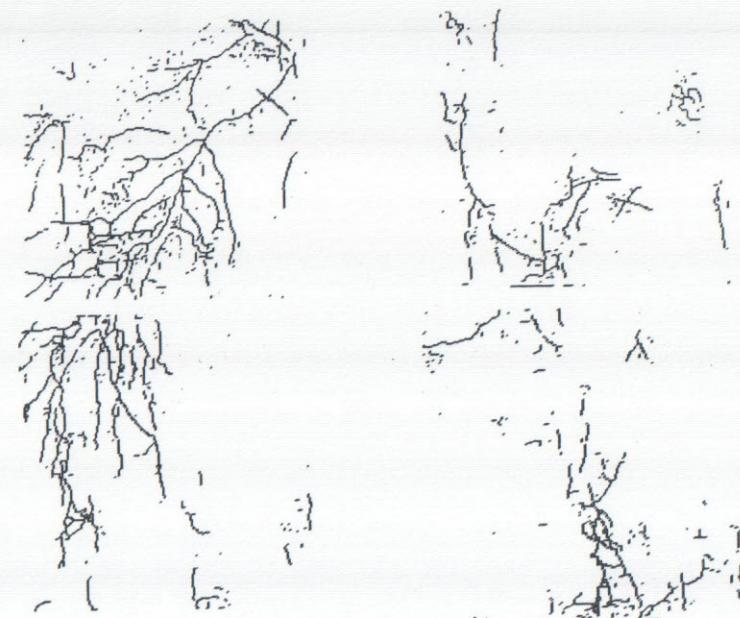


Figura 22. Segmentação da imagem de perfil de raízes da Figura 19 através do SIARCS.

Aplicando-se a transformada de distância, também pode ser feito o mesmo processo para determinação de classes de diâmetros, como pode ser visto na Figuras 23 e 24.

Os resultados com o SIARCS® apresentados por Crestana et al. (1994), mostraram a viabilidade da metodologia na avaliação da distribuição do sistema radicular de plantas cultivadas. A partir deste, vários trabalhos foram realizados em diferentes culturas, tais como: milho (BASSOI et al., 1994a; BASSOI et al., 1994b; ABI SAAB et al., 1996; JORGE et al., 1996), forrageiras (ROCHA FILHO et al., 1996), soja (CRESTANA et al., 1994), videira (BASSOI e ASSIS, 1996), citrus (CINTRA e NEVES, 1996); e sistemas de manejo, tais como: semeadura direta e preparo convencional (FANTE-JÚNIOR. et al., 1994; GUIMARÃES et al., 1996). Vários outros continuam sendo efetuados apresentando ótimas correlações.

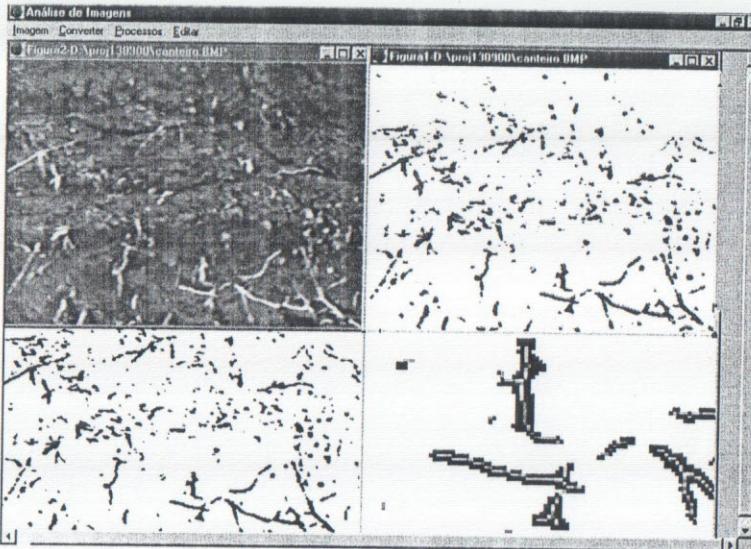


Figura 23. Imagem de perfil de raízes e seu processamento.

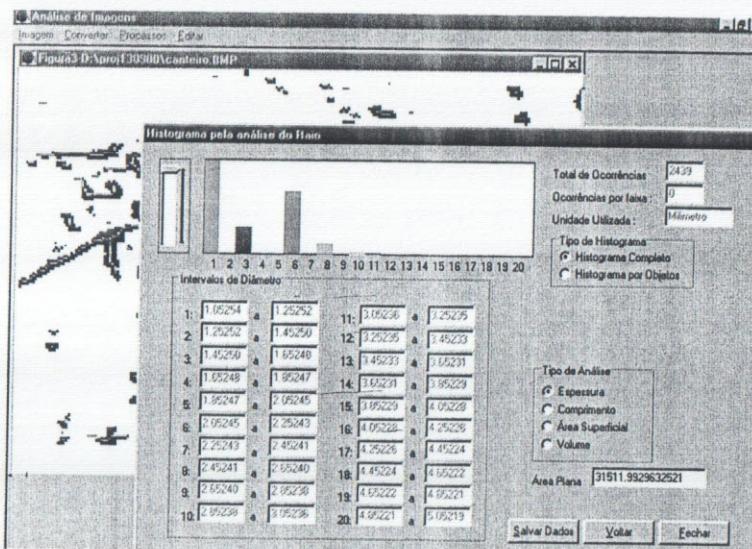


Figura 24. Histograma de distribuição de diâmetros das raízes.

Além do SIARCS® desenvolvido pela Embrapa, existem outras opções de software no mercado disponíveis para análise de raízes, como o CI - 600, WinRhizo e MSU Root Tracer¹.

Conteúdo do CD: Software para análise de raízes

Está sendo disponibilizado no CD o software para análise de raízes, descrito nos itens anteriores deste capítulo. A versão disponibilizada é uma versão beta e se encontra em fase de desenvolvimento, o que pode apresentar alguma dificuldade inicial para uso. Foi desenvolvido para ambiente Windows XP e necessita de pelo menos 512MB de memória RAM e um espaço de 20GB em HD para operar adequadamente. Qualquer dúvida deve-se entrar em contato através do e-mail sac@cnpdias.embrapa.br.

O conteúdo pode ser encontrado através do diretório \SIARCS no CD. Neste, são disponibilizadas imagens, roteiro para utilização e duas versões do software, a versão 3.0 e a versão 2006.

Aplicação do processamento de imagens no estudo da morfologia do solo

A morfologia do solo desempenha importante papel no estudo dos parâmetros que determinam sua estrutura e influenciam nos processos que ocorrem nesse meio poroso. A estrutura do solo, resultante de processos físicos, biológicos e climatológicos, desempenha papel de relevância nos fatores que determinam o desenvolvimento de plantas e o desempenho da produção agrícola, estando ligada à capacidade desse meio em armazenar calor, gás, água e nutrientes. As características dessa estrutura têm sido examinadas sob ampla faixa de escalas.

Os sistemas de manejo agrícola, principalmente agricultura intensiva e irrigação, têm provocado compactação do solo reduzindo fortemente a capacidade de infiltração, capacidade de retenção de água e dificultando o desenvolvimento do sistema radicular. Assim, avaliar e estudar a modificação de estrutura do solo e a porosidade torna-se de extrema importância quando se acompanha um manejo agrícola.

Hoje em dia, o processamento de imagens tem um papel essencial na medida e caracterização de partículas em diferentes áreas de

¹ www.cid-inc.com./products/ci-600; www.regent.qc.ca; www.roots.rsgis.msu.edu/roots.doc

investigação. Na área de solos, contribui significativamente na determinação de medidas com alta precisão, com baixo custo e análises rápidas.

O processamento de imagens de solo, por tomografia e ou lâminas delgadas, usando técnicas de morfologia matemática permitem a avaliação do espaço poroso do solo e seus agregados, de forma quantitativa. Um exemplo desta foi apresentado por Jorge et al. (2001).

As técnicas de processamento de imagens aplicadas no estudo morfológico do solo são apresentadas na Figura 25. Após a aquisição das imagens, por tomografia ou por lâminas de solo, devem ser efetuadas a segmentação das estruturas de interesse, poros ou agregados, a aplicação da granulometria morfológica e a respectiva análise de forma.

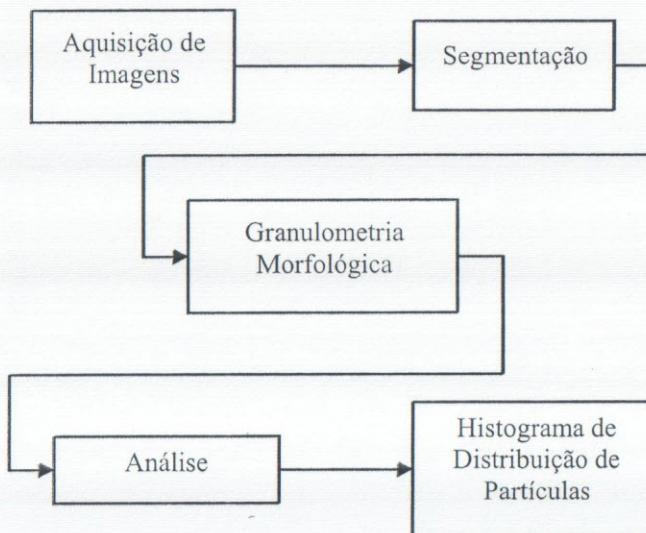


Figura 25. Diagrama de técnicas de imagem no estudo da morfologia do solo.

A granulometria é um processo morfológico responsável por caracterizar uma imagem com relação à distribuição do tamanho de partículas encontradas na mesma. Com isto, pode-se caracterizar a distribuição de poros e agregados do solo, por tamanho e forma. Existem diferentes formas de análise granulométrica: por abertura, por reconstrução e por fechamento. Cada uma destas depende do tipo de processamento

morfológico implementado. O método reconstrutivo é mais preciso, porém com custo computacional muito maior.

Observa-se que ele tem a vantagem de manter a forma original dos objetos que estão sendo analisados. A Figura 26 apresenta o resultado de processo de granulometria por abertura com reconstrução binária e a Figura 27 sem a reconstrução. Nota-se neste caso, que a granulometria sem a reconstrução deforma o resultado final, podendo não separar as estruturas de real interesse.

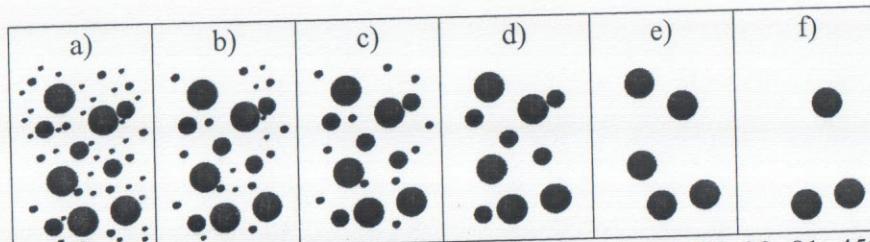


Figura 26. Imagem artificial com círculos de diâmetros 26, 29, 81, 459, 1277 e 1292 pixels (a). O resultado da análise granulométrica por granulometria binária por reconstrução depois de 2 (b), 3 (c), 4 (d), 9 (e) e 14 (f) iterações.

Da mesma forma, utilizando lâminas de micrografias de um mesmo solo (CURMI et al., 1992) em floresta nativa ou área de cultivo, podem ser observadas as diferenças na estrutura do solo provenientes do manejo. Na Figura 28, podem ser observadas as imagens de lâminas delgadas de um mesmo solo, diferenciando-se seu manejo: cultivo e mata nativa.

Nota-se claramente na Figura 28 que existem agregados com formas e tamanhos diferentes próximos à superfície e relativamente iguais quando aumenta a profundidade.

O elemento estruturante mais próximo de um círculo digital foi adotado neste caso, supondo-se ser este o melhor modelo para poro ou agregado. Não obstante, existem poros com outros formatos, como os fissurais. Neste caso, deve-se optar por elementos estruturantes alongados. O elemento estruturante é definido inicialmente por um pixel e vai crescendo conforme o critério de crescimento estabelecido. Na Figura 29, observa-se o elemento estruturante inicial e após a primeira e a segunda interação.

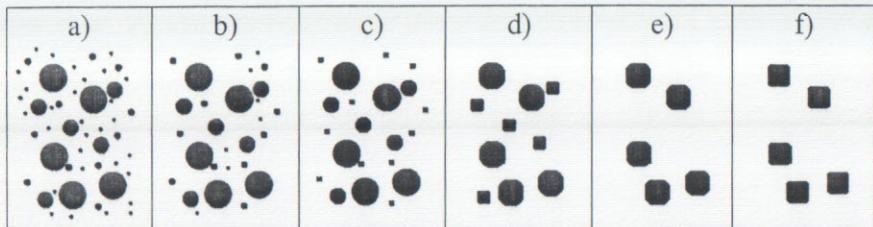


Figura 27. Resultado da granulometria binária por abertura com 1 (a), 2 (b), 3 (c), 6 (d), 9 (e) e 12 iterações (f).

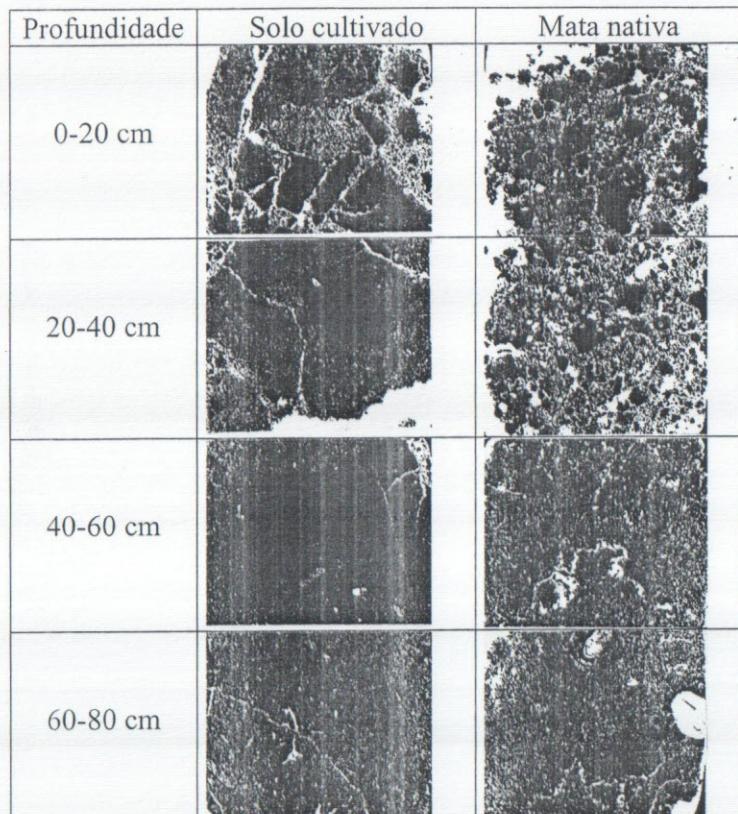


Figura 28. Imagens de lâminas delgadas solo de mata nativa e cultivado (JORGE et al., 2001)

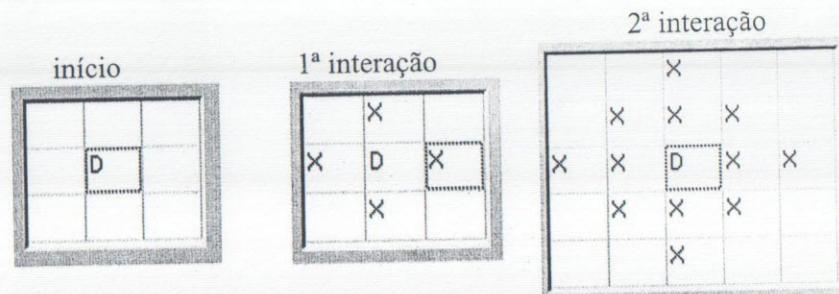


Figura 29. Elemento estruturante e sua forma de crescimento.

Na Figura 30, apresentam-se os resultados do processo granulométrico para estudo da distribuição de poros e agregados. Para tanto, as imagens foram segmentadas por Otsu, gerando imagens binárias com o objeto a ser medido em preto e o restante em branco, ou seja, ora poros ora agregados.

O processo de peneiramento foi utilizado começando com um elemento estruturante como um pixel e crescimento segundo a Figura 29.

Neste caso, o mínimo da malha da “peneira”, é o tamanho do pixel. Portanto, a resolução utilizada na digitalização das imagens das lâminas torna-se importante em todo o processo.

Quanto maior for a resolução, maior será a precisão da análise.

Outro fator a ser considerado nesta análise é a presença de falhas nas lâminas, principalmente nas bordas. Sendo assim, na tentativa de minimizar tais erros, seleciona-se na imagem uma sub-região representativa de poros e agregados e se faz a análise.

Na Figura 31 pode-se observar a distribuição do tamanho dos agregados encontrados na imagem, sendo todas as medidas apresentadas em pixels.



Figura 30. Resultado da granulometria binária com 7 iterações, para a imagem de mata de 20-40 cm (JORGE et al., 2001).

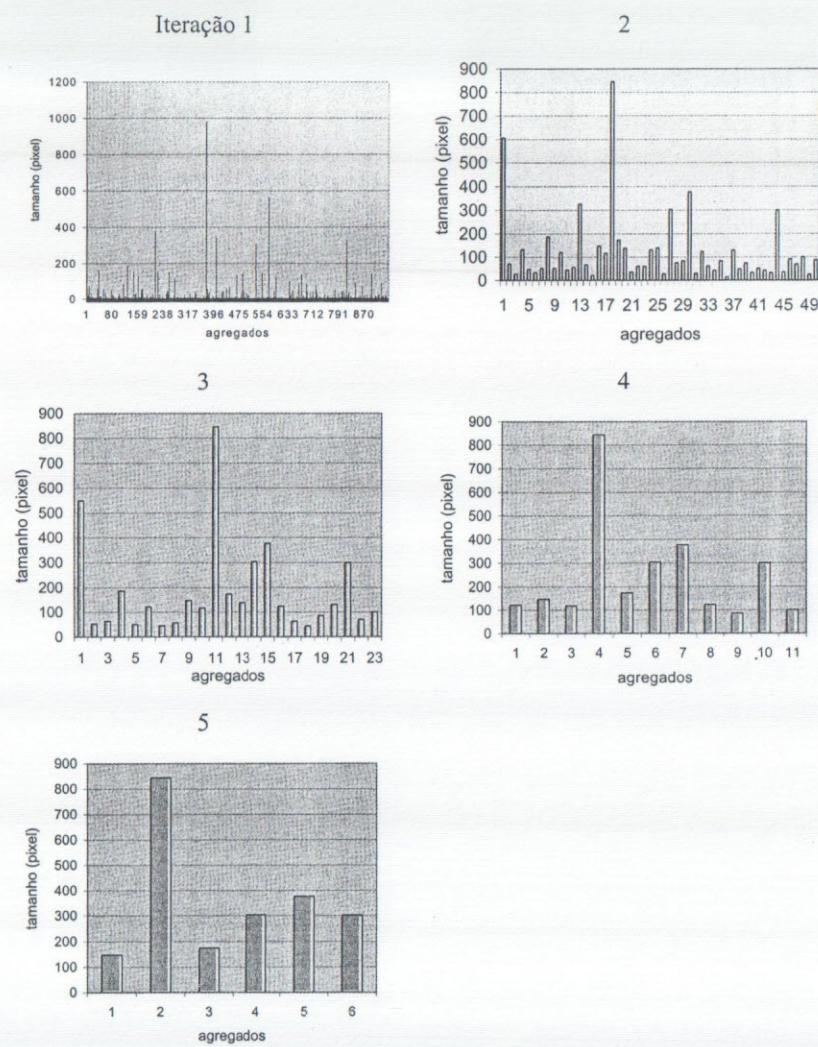


Figura 31. Distribuição de agregados por tamanho após cada peneiramento (JORGE et al., 2001).

Na Figura 32, pode-se observar o histograma granulométrico do total retirado da imagem a cada iteração.

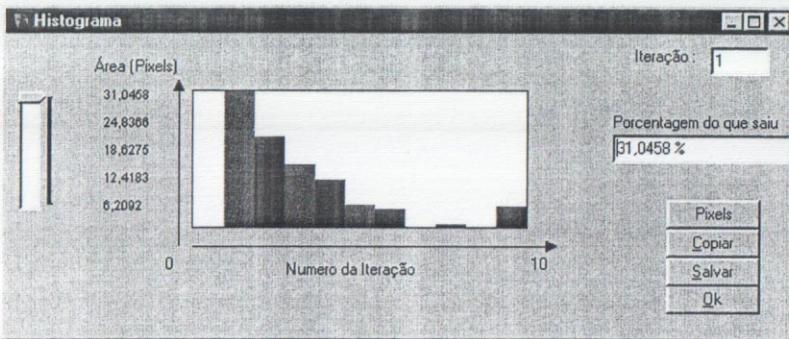


Figura 32. Área nas iterações do processo granulométrico (mata 20-40).

Da Figura 33 à Figura 36, pode-se observar o processo granulométrico para algumas das imagens de solo cultivado.

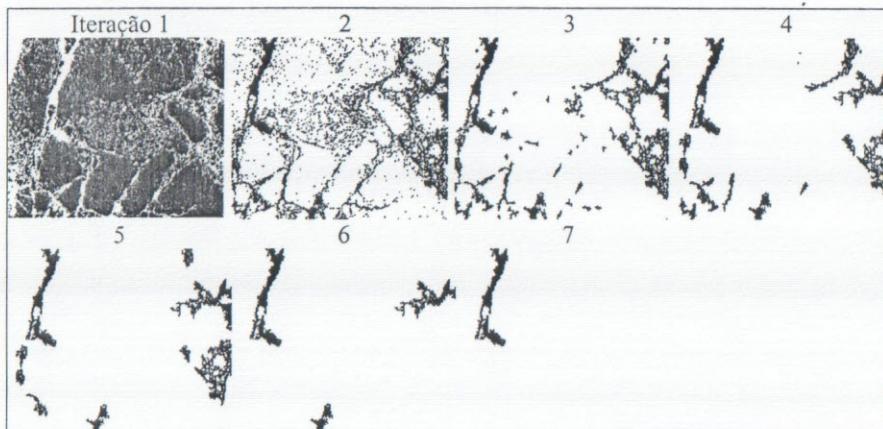


Figura 33. Granulometria de poros (imagem de solo cultivado 0-20cm).



Figura 34. Granulometria de poros (imagem solo cultivado 20-40 cm).

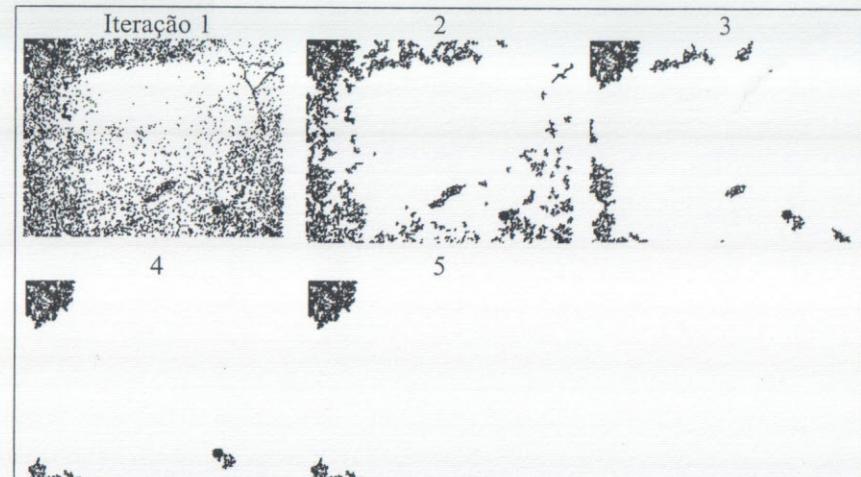


Figura 35. Granulometria de poros (imagem solo cultivado 40-60 cm).

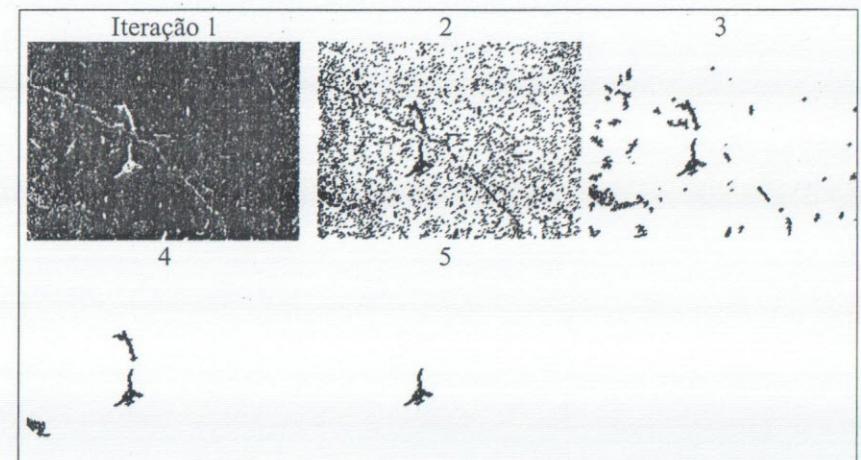


Figura 36. Granulometria de poros (imagem solo cultivado 60-80 cm).

Na Figura 37 apresenta-se uma imagem de tomografia micrométrica de um torrão de solo e a sua respectiva granulometria.

Devido à importância da granulometria na análise de meios porosos e diversas outras aplicações ainda há melhorias a serem feitas até que um processo ótico totalmente equivalente ao processo de peneiramento mecânico seja obtido.

De maneira geral, pode-se afirmar que o algoritmo simples apresentado apenas se mostra adequado para avaliações de imagens com grãos regulares onde é possível a utilização de elementos estruturantes com as formas dos grãos presentes na imagem. O algoritmo pode ser utilizado em casos mais genéricos. Mesmo assim pode haver falha na interpretação do diâmetro do grão encontrado, e sua substituição pelo do diâmetro do elemento estruturante.

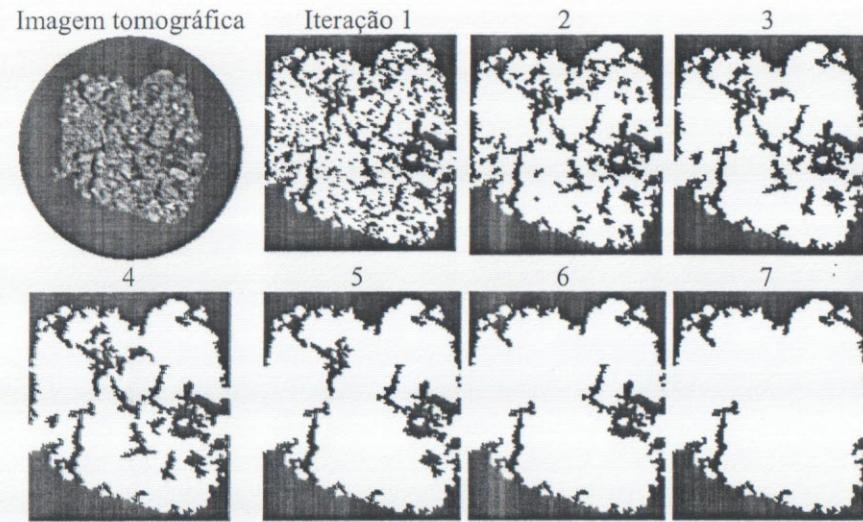


Figura 37. Granulometria de um torrão de solo.

Processamento de imagens no estudo da cobertura do solo

A avaliação da área de solo coberta por plantas, resíduos e palhas, é de interesse para o manejo dos solos em diversos aspectos. Do ponto de vista da fisiologia, é a área que intercepta a luz solar para a fotossíntese. Para o balanço de água no solo define as superfícies de evaporação e de evapotranspiração. A área coberta por diferentes tipos de plantas indica a competição entre as culturas e a flora infestante. Mas, sem dúvida, a importância da cobertura vegetal está no seu efeito sobre o controle da erosão dos solos.

Geralmente a análise das imagens aéreas é capaz de detectar propriedades importantes para o acompanhamento da área agrícola, tais como (MORAN et al., 1997):

-*Propriedades dos solos:* as características físicas, como teores de matéria orgânica, textura, permeabilidade, dos diversos tipos de solos podem ser correlacionados com a resposta espectral registrada em imagens provenientes dos campos. Ainda que influenciadas por outras variáveis como tratos culturais, umidade, uma adequada seleção de bandas espetrais e resolução espacial, as imagens podem proporcionar uma boa caracterização dos solos dentro de um campo de cultivo, gerando a identificação de zonas homogêneas de propriedades físicas do solo. Uma identificação deste tipo pode ser uma ferramenta poderosa para a interpolação de parâmetros de amostras de solo coletadas em campo, ajustando os modelos de interpretação de maneira a se produzir um excelente mapa de sítios homogêneos, os quais servem de base para a definição de tratos culturais e aplicações diferenciadas dentro do campo.

-*Conservação do solo:* muitos cultivos principais e secundários são avaliados em relação a sua taxa de cobertura do solo visando, principalmente, a proteção do mesmo contra o impacto das gotas de chuva. Estas causam, dentre outros efeitos, um selamento superficial do solo e processos de erosão. Imagens de alta resolução permitem calcular a cobertura do solo com precisão e alimentam modelos de previsibilidade de erosão permitindo assim uma ação preventiva e corretiva. Estas técnicas também são úteis para manejos como o plantio direto onde se torna importante a determinação de matéria seca sobre o solo.

Cobertura vegetal e erosão

A erosão tem sido a principal causa da degradação dos solos e do ambiente em muitas regiões tropicais e subtropicais. O processo de desprendimento e arrastamento de partículas do solo pela ação das chuvas, das enxurradas e do vento, e de deposição desse material, especialmente nos cursos de água, causa a perda de qualidade do solo, a redução da produtividade e o assoreamento de rios e represas.

Entre os fatores que interferem no processo erosivo estão a erosividade da chuva ou do vento, a erodibilidade do solo frente aos agentes erosivos, o relevo e a cobertura vegetal. A retirada da vegetação ou a exposição do solo à ação direta dos agentes erosivos causam elevadas perdas de solo. A cobertura vegetal atua como uma proteção natural do solo contra a erosão. As folhas e restos de vegetação interceptam a chuva antes que esta atinja o solo, protegendo a superfície contra o impacto direto das gotas que causam a desagregação das partículas de solo e atuam como barreiras que reduzem a velocidade das enxurradas e dos ventos. O

efeito da vegetação na erosão resulta também da manutenção de maior umidade da superfície do solo e da incorporação de material orgânico, que melhora a estabilidade da estrutura do solo, aumentando as taxas de infiltração de água e a resistência do solo.

A cobertura vegetal, expressa em porcentagem da área coberta em relação à área total, é mais importante do que a quantidade total de plantas ou restos vegetais sobre o solo, expressa em massa de material vegetal por área, nas perdas de solo e água por erosão hídrica. Trabalhos como o de Elwell e Stocking (1976) demonstram que a porcentagem de cobertura vegetal é o principal fator determinante da erosão em culturas anuais e pastagens, enquanto Stocking (1988) sugere que uma cobertura vegetal de 60% é suficiente para um efetivo controle da erosão. Na erosão eólica a porcentagem de área coberta tem também um papel importante, associado à altura, à densidade e à orientação dos resíduos e das plantas. O efeito da cobertura por resíduos sobre as perdas por erosão tem sido representado pela equação $E = a \cdot e^{(b \cdot \%C)}$, onde E é a erosão, a e b são coeficientes e $\%C$ é a porcentagem de cobertura.

Para explicitar essa relação, Laflen e Colvin (1981) sugerem, também, a utilização do fator de cobertura (FC), que é determinado dividindo-se a equação anterior pelo valor da interseção (a). O efeito do manejo dos restos culturais depende da quantidade deixada sobre o solo, que é função da produtividade, das chuvas, da fertilidade do solo, etc. e da taxa de decomposição, que é função da composição da planta, do tamanho dos resíduos, etc. McGregor et al. (1988) apresentam essa equação para diferentes tipos de resíduos.

A eficiência da cobertura vegetal depende ainda de características da vegetação e da interação entre a cobertura vegetal, o solo e o declive (LAFLEN e COLVIN, 1981). Vegetação arbórea e florestas podem cobrir totalmente o solo. Stocking e Elwell (1976), entretanto, demonstram que a porcentagem de cobertura é pouco efetiva em reduzir a erosão se a altura do dossel for muito alta, uma vez que as gotas de água que caem das folhas atingem velocidade terminal e tem massa maior do que as gotas da chuva. Portanto, tem maior erosividade.

O ciclo vegetativo das espécies cultivadas oferece diferentes graus de cobertura e de proteção ao solo durante o seu desenvolvimento em função da massa foliar. A cobertura vegetal depende, também, do espaçamento entre linhas e da população de plantas. A influência dessa cobertura na taxa de erosão da área depende de como as chuvas erosivas ocorrem durante o desenvolvimento da cultura. Nas culturas anuais o

período mais crítico é o que vai do preparo até que a cultura ofereça suficiente proteção à área. A variação da cobertura no tempo é, normalmente, representada por equações, sendo as mais comuns as dos tipos logística e exponencial cúbica.

Existe um número muito grande de possíveis combinações de culturas, rotações e manejos que resultam em diferentes porcentagens de cobertura e de proteção ao solo. No manejo do solo, para reduzir a erosão, diversas técnicas agronômicas procuram assegurar uma adequada cobertura ao solo como cobertura morta, alternância de capinas, cultivo mínimo e plantio direto.

A determinação da cobertura vegetal do solo por resíduos e por plantas tem sido utilizada para avaliar diferentes tipos de manejo e culturas visando, principalmente, ordenar os sistemas quanto à proteção que oferecem contra a erosão e, também, para verificar seu efeito sobre água disponível, temperatura e controle da flora infestante. Valores da cobertura são utilizados, ainda, para calcular fatores de modelos de estimativa da erosão, como a USLE, a RUSLE e o WEPP, que são instrumentos para o planejamento conservacionista.

Determinação da cobertura do solo por imagens

Entre os diferentes métodos utilizados na avaliação da cobertura vegetal, os mais comuns são os métodos: da régua, da *armação de visadas localizadas*, da *corda com nós*, da *interceptação da luz solar*, da *largura do dossel vegetativo* e o *fotográfico*. Quase todos esses métodos são trabalhosos e apresentam limitações de naturezas diversas. A escolha do método deve levar em consideração esses fatores, além da acuracidade.

O *método fotográfico* consiste em tomar fotografias da superfície do terreno e depois analisá-la para avaliação da porcentagem de cobertura vegetal. Este método se destaca como um dos mais utilizados para avaliação de cobertura vegetal e, também, para outros fins como coleta de dados sobre a composição de espécies da vegetação (ELWELL e GARDNER, 1976). Apesar das limitações que apresenta, muitas vezes é utilizado como referência para avaliação de outros métodos (LOWERY et al., 1984). O método fotográfico apresenta como vantagens: fornecer observações permanentes, pequeno tempo de observação no campo em relação à maioria dos métodos e pouca influência das condições atmosféricas (vento, sol, nuvens).

Como desvantagens deste método têm sido apontadas: o custo e o tempo de análise das imagens, a projeção não vertical, a distorção da imagem fotográfica, que aumenta do centro para a periferia da foto, limitando sua área útil, a necessidade de que a câmara fotográfica seja elevada em relação à altura da cultura (ELWELL e GARDNER, 1976; ELWELL e WENDELAAR, 1977), a possibilidade de perda de dados por falhas na câmara fotográfica, ou no processamento das fotos (HARWIG e LAFLEN, 1978), o contraste necessário entre plantas e solo.

A exatidão do método foi avaliada por Cogo e Amado (1986), em condições controladas de laboratório, na determinação da porcentagem de cobertura do solo por resíduos culturais. Os valores de cobertura estimados por esses autores apresentaram correlação elevada com os valores reais ($r=0,99$) a 1% de probabilidade. Por outro lado, Williams (1979) analisou a porcentagem de erro do método fotográfico na medição da cobertura vegetal e concluiu que o grau de erro é relacionado à estrutura da planta e é mínimo em culturas densas. Esse mesmo autor apontou que o erro pode ser reduzido usando-se só a porção central da fotografia (reduzindo o ângulo de visão da câmara) ou mediante o uso de uma lente com grande distância focal.

Quanto ao número de observações necessárias para avaliação da cobertura, Pereira, et al. (1986) concluíram que para percentagem de cobertura superior a 50% foram necessárias pelo menos 15 medidas para que este método fornecesse resultados satisfatórios. Enquanto Sallaway et al. (1988) medindo cobertura de resíduos de sorgo, determinaram que 24 fotos seriam necessárias para obter resultados representativos, embora com apenas 6 fotos em locais fixos tenham conseguido médias e desvios similares aos obtidos com as 24 fotos ao acaso.

O procedimento mais utilizado neste método foi a obtenção das imagens utilizando um filme colorido convencional, estando a câmara, acionada por controle remoto, suspensa em uma estrutura metálica móvel a uma altura de 5 a 8 metros (ELWELL e WENDELAAR, 1977; SALLAWAY et al., 1988; JONG VAN LIER et al., 1993).

Sloneker e Moldenhauer (1977) citam uma variação do um método fotográfico que utiliza fotografias tomadas com um filme tipo slide de 35 mm, para medir a cobertura de resíduos, por meio de um densitômetro, que fornece valores digitais de intensidade da luz, podendo-se determinar as diferenças de reflectância entre a cobertura vegetal e um fundo de diferente cor. De acordo com Lowery et al. (1984), o densitômetro mede a densidade de luz que atravessa o filme, qual depende da opacidade da

imagem. Esses autores verificaram que este método subestima a porcentagem de cobertura quando a rugosidade da superfície é grande, como quando se prepara o solo com escarificador.

Devido à evolução de sensores ótico-eletrônicos, equipamentos que identificam a presença de resíduos, baseados em reflectância ou fluorescência, estão sendo desenvolvidos e poderão, em um futuro próximo, estar sendo utilizados para determinar a porcentagem de cobertura por resíduos (MORRISON et. al., 1993).

Os meios tradicionais para a obtenção de imagens aéreas utilizam aeronaves tripuladas. O custo de operação dessas aeronaves torna o seu uso proibitivo em pequenas e médias propriedades agrícolas, principalmente quando são necessárias imagens obtidas com uma periodicidade muito elevada ou em grande quantidade. A utilização de meios não convencionais para a obtenção dessas imagens aéreas pode minimizar de forma significativa o seu custo. Nesta seção são apresentados dois métodos para a obtenção de imagens aéreas. O primeiro baseado em uma torre de filmagem, possibilita a obtenção de imagens aéreas de alta resolução de pequenas áreas de solo a baixa altitude. O segundo método, baseado em aeronaves em escala reduzida, apresenta muitas vantagens em relação à utilização de aeronaves convencionais. Além de um custo mais baixo por imagem, essas aeronaves podem operar em condições impraticáveis para as aeronaves tripuladas.

A partir das fotografias foram desenvolvidos diversos métodos com a finalidade de avaliar a porcentagem ocupada na foto pela imagem fotográfica da cobertura vegetal, sendo o mais comum aquele que faz uma avaliação estatística da cobertura pela leitura de uma malha regular de pontos de observação colocada sobre a foto (JORGE et al., 1996). Em um outro método a imagem fotográfica da cobertura vegetal é transcrita manualmente para um papel vegetal colocado sobre a foto, sendo a seguir a imagem no papel transferida, em branco e preto, pelo emprego de um "scanner", para a tela de um microcomputador onde é preparada para ser processada segundo um programa para cálculo da porcentagem de cobertura (JONG VAN LIER et al., 1993).

Morrison et al. (1993), utilizando slides, tirados com uma câmara equipada com uma lente de 50 mm., posicionada verticalmente acima do solo a distâncias focais de 1, 1,5 e 2 metros, determinaram a cobertura vegetal mediante a utilização de urna tela de projeção de 56 cm² com 100, 200 e 300 pontos localizados ao acaso e concluíram que a distância

focal não afeta a estimativa de cobertura por resíduos localizados até 25 cm acima da superfície do solo; no entanto a distância focal teve efeitos significativos na estimativa da cobertura por resíduos acima de 60 cm da superfície do solo. Esses mesmos autores concluíram também que a tela de projeção com pontos é mais apropriada para comparação de tratamentos do que para determinar valores absolutos de cobertura por resíduos.

A partir da fotografia, diferentes formas de avaliação têm sido apresentadas (JORGE et al., 1993). Como uma variação destes métodos, encontra-se o SIARCS®, cujas características de processamento e análise de imagens proporcionam uma avaliação rápida e precisa da cobertura vegetal sobre o solo, bem como a taxa de ocupação por palha e outros resíduos. A avaliação da cobertura vegetal através do SIARCS® é feita a partir de fotografias digitalizadas ou de imagens filmadas e posteriormente digitalizadas. Determina-se a porcentagem da área ocupada pela cobertura vegetal ou de palha, através da avaliação das suas cores, apresentando os resultados da medida da área em unidades internacionais ou em porcentagem da área da imagem. A aquisição da imagem também se apresenta como uma etapa importante para a definição da qualidade e precisão dos resultados finais. Requer, assim, cuidados que vão desde a escolha da forma de filmagem, a iluminação, até a digitalização.

Torres de filmagem

Nos vários trabalhos encontrados onde se utiliza um suporte tipo torre para aquisição da imagem, pode-se encontrar diferentes tamanhos e formas para a mesma, de altura ajustável e com braço giratório. O suporte de filmagem com altura ajustável, desenvolvido pela Embrapa Instrumentação Agropecuária, foi confeccionado com tubos de alumínio, de 3 e 2,8 cm de diâmetro, na forma de um L invertido, com altura máxima de 6 e mínima de 3 metros. Este, porém, necessita de duas pessoas para posicioná-lo e em dias com muito vento, pode apresentar dificuldades. A variação da distância a ser filmada, através da altura da câmera, não se mostrou necessária. A torre com braço giratório, considerada um suporte resistente, inclusive para sua utilização em dias de muito vento, foi confeccionada de tal forma a permitir que apenas um operador conseguisse fazer as tomadas e que não houvesse a necessidade de desmontá-la, podendo servir para a avaliação da dinâmica de crescimento da cultura de cobertura. Também permite a aquisição de

mais imagens num mesmo ponto de amostragem, com a movimentação do braço, como pode ser visto na Figura 38.

A torre desenvolvida (pedido de patente protocolado junto ao INPI sob o número 004276) é constituída de três partes (Figura 39): um tripé, uma haste e um braço. O tripé possui um mancal, onde se apóia a estrutura da haste, e um rolamento através do qual é possível girar a mesma. O braço é apoiado em um rolamento, que permite o giro junto com a haste. A haste é composta de tubos galvanizados de 1" de diâmetro, conectados por luvas de união e estirados por meio de cabos de aço. A altura, incluindo o tripé, é 8 m e o comprimento do braço 3,5 m.

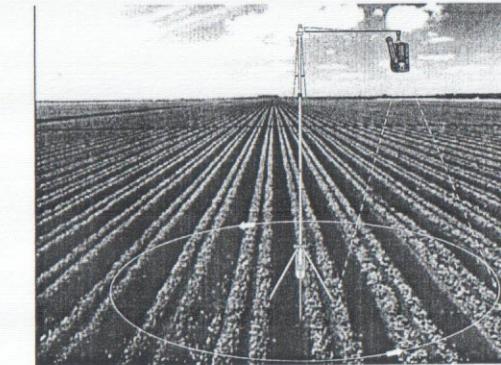


Figura 38. Utilização da torre de filmagem no campo.

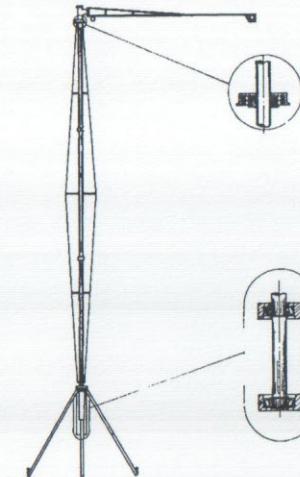


Figura 39. Diagrama esquemático da torre desenvolvida pelo CNPDIA EMBRAPA para aquisição de imagens de cobertura vegetal.

O tripé pode ser confeccionado em mais unidades, de igual número ao dos pontos de amostragem. Assim, pode-se posicioná-los nos devidos pontos de amostragem e apenas movimentar o restante da torre nos diferentes pontos de amostragem.

Para análise automatizada das imagens por computador, as condições de luz devem ser observadas, pois a intensidade dos raios solares e o horário do dia em que são feitas as tomadas de imagens podem provocar reflexos e efeitos de sombra da planta no solo dificultando a análise. Pode-se utilizar, como alternativa, anteparos para deixar na sombra a área a ser filmada. Os dias nublados são os mais propícios para se fazer a filmagem, devendo-se evitar os horários com o sol a pino.

A câmera fotográfica ou filmadora deve ser selecionada de maneira que possa ser fixada na ponta da torre sem problemas e para isso as filmadoras portáteis são as mais práticas. Tanto na filmadora quanto na câmera é conveniente a utilização de disparadores automáticos ou por controle remoto.

A grande vantagem das torres de filmagem é a alta resolução das imagens proporcionada pela baixa altitude de operação. Por outro lado, o sistema tem operação complicada, exigindo operações de montagem e desmontagem freqüentes. Outra desvantagem é a pequena área coberta por cada imagem, tornando o sistema adequado apenas para aplicações específicas.

Aeronaves

O monitoramento por imagens aéreas na agricultura tem provado ser útil para uma série de objetivos, tais como: qualidade de plantio, emergência ou brotamento da cultura; mapeamento de plantas invasoras; densidade de palha sobre o solo; zoneamento de solos e de áreas homogenias de manejo; drenagem natural da parcela; amostragem de solo orientada; crescimento e desenvolvimento da cultura até à maturação; previsão de safra; avaliação da densidade da copa ou vigor da cultura; dentre outras (MORAN et al., 1997; MOLIN, 1997).

Neste sentido, foi desenvolvido na Embrapa Instrumentação Agropecuária uma técnica de processamento de imagens aéreas para atender estes objetivos (JORGE et al., 1999; JORGE, 2001). Esta técnica, apesar de utilizada nas imagens obtidas por aeromodelo, pode ser utilizada também em imagens aéreas provenientes de outros tipos de aeronaves.

Análise das imagens aéreas

Uma vez obtidas as imagens, o processamento das mesmas passa pelas seguintes etapas: obtenção das imagens, pré-processamento, processamento, segmentação dos temas de interesse nas imagens; extração de índices para cada tema, geração de mapas e recomendação final, conforme se mostra na Figura 40.

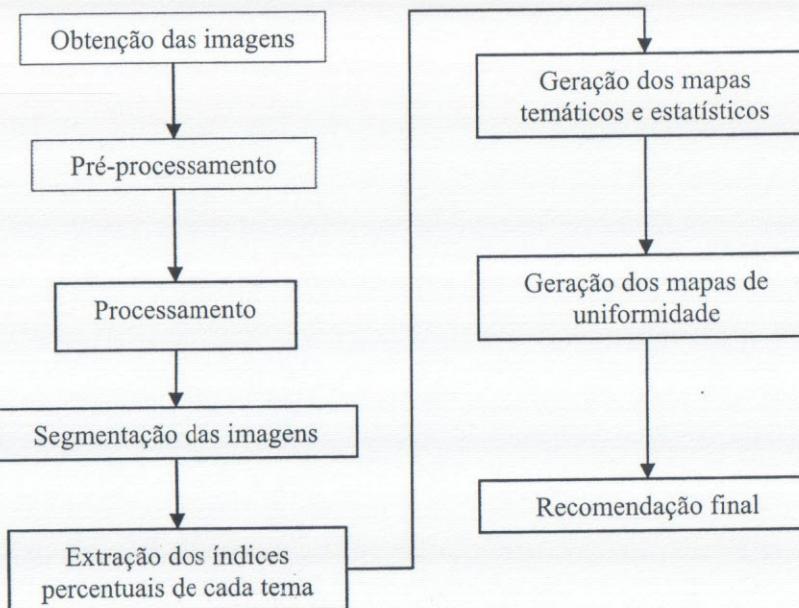


Figura 40. Etapas da análise das imagens aéreas.

Obtenção das imagens

A obtenção das imagens pode ser feita com o aeromodelo desenvolvido pela Embrapa Instrumentação Agropecuária, conforme descrito na Circular Técnica 15 (JORGE e TRINDADE JUNIOR, 2002). Não obstante, pode-se utilizar também outra plataforma, levando em conta a influência da movimentação da aeronave na qualidade das imagens.

A nitidez das imagens obtidas a bordo de uma aeronave depende da estabilidade da aeronave em vôo. Aeronaves em escala reduzida são menos estáveis e apresentam maior vibração mecânica que as aeronaves em tamanho real. Quanto menor for o tempo de exposição na obtenção, maior será a possibilidade de obtenção de imagens nítidas com a

aeronave em movimento e sujeita a vibrações. Os fatores que afetam a qualidade das imagens obtidas são os seguintes:

- Sensibilidade do elemento capturador de imagem;
- Abertura do diafragma (ou íris);
- Tempo de exposição;
- Condições de iluminação do local;
- Velocidade horizontal da aeronave;
- Vibração linear da aeronave na direção dos eixos de arfagem e rolagem;
- Vibração angular da aeronave em relação aos eixos de arfagem, rolagem e guinada.

Uma característica importante para a obtenção de imagens nítidas é a velocidade de vôo da aeronave. Quanto mais baixa for essa velocidade, maior é a possibilidade de obtenção de imagens nítidas para uma mesma condição de iluminação. A velocidade mínima de vôo de uma aeronave depende do seu tipo. Em balões e helicópteros essa velocidade é igual a zero. Em aviões, a velocidade mínima de vôo está intimamente relacionada com a velocidade de estol, que pode ser estimada pela expressão:

$$V_s = \sqrt{\frac{P * 1,6}{C_{s\max} * SA * Da}}$$

onde V_s (m/s) é a velocidade de estol, P (g) é o peso da aeronave, SA (dm^2) é a área da asa, Da é a densidade do ar no nível do mar =1 e a 1500 m = 0,8616, $C_{s\max}$ é o coeficiente de sustentação máximo, normalmente próximo de 1.

A sensibilidade do capturador da imagem é fixa. Filmes químicos apresentam alta sensibilidade que pode variar entre algumas dezenas até alguns milhares de unidades ASA. Câmeras fotográficas digitais atuais já apresentam sensibilidade equivalente ao redor de 100 ASA, 400ASA, 800ASA.

A abertura do diafragma não é importante quanto ao aspecto de profundidade de campo uma vez que, na maioria das aplicações, a altitude do avião é muito maior que a altitude do relevo do solo que está sendo fotografado. Em certos casos, entretanto, ela deve ser considerada, como por exemplo, na fotografia em baixa altitude de matas ou culturas de eucaliptos, onde se deseja ter em foco tanto a copa das árvores quanto

o solo. A possibilidade de controle automático da abertura do diafragma é uma característica desejável. Se a câmera dispuser de um modo para fotografia de eventos rápidos, por exemplo, esportes, é possível utilizar a abertura do diafragma como meio básico de controle da exposição, mantendo-se o tempo de exposição sempre o mais elevado possível.

As condições de iluminação do local variam com a época do ano e com as condições climáticas. Juntamente com a sensibilidade do elemento capturador de imagens, elas determinam qual deve ser a combinação entre a abertura do diafragma e o tempo de exposição para uma correta exposição. A influência da velocidade horizontal da aeronave sobre a velocidade de obturador para a obtenção de fotos nítidas pode ser estimada como descrito a seguir (SOUZA, 1999).

Para os cálculos seguintes, admite-se que a resolução da câmera é de $Ph \times Pv$ pixels e que, a aeronave se movimenta no sentido da maior dimensão da imagem, no caso assume-se Ph pixels. Admite-se, também, que o avião pode se movimentar no máximo uma distância de $\frac{1}{2}$ pixel durante a exposição para que as imagens permaneçam razoavelmente nítidas. Neste caso, o espaço de solo coberto por cada pixel depende da altitude do avião sendo dado pela seguinte equação:

$$Cp = \frac{h}{Ph}$$

onde h (m) é a distância horizontal coberta pela imagem, Ph é o número de pixels na maior dimensão da imagem, Cp é o comprimento do pixel.

Considerando-se a equação anterior, segue que o tempo de exposição deve ser tal que:

$$To = \frac{Cp}{2 \cdot Va} = \frac{h}{2 \cdot Ph \cdot Va} = \frac{K1 \cdot A}{2 \cdot Ph \cdot Va} = \frac{K2 \cdot A}{Va}$$

onde To é o tempo de exposição, Va (m/s) é a velocidade da aeronave.

Observa-se dessa equação que o tempo de exposição diminui com a velocidade da aeronave e aumenta com a altitude A .

O efeito da vibração linear da aeronave em relação aos eixos de arfagem e rolagem (Figura 41) sobre a nitidez das fotos pode ser tratado de forma semelhante ao que foi feito para a velocidade horizontal da aeronave.

A vibração é caracterizada por um movimento oscilatório linear onde a velocidade cai a zero nos extremos do movimento e atinge um máximo em algum ponto do deslocamento. Esse valor máximo pode ser utilizado

na equação anterior para a estimativa do tempo de exposição. A aeronave pode ser instrumentada adequadamente para a obtenção prática desses valores.

O último aspecto que pode influenciar a nitidez das imagens obtidas é a estabilidade angular do avião em qualquer um dos seus três eixos de controle. Ao girar nesses eixos, o avião muda a direção para onde a câmera está apontada a uma velocidade angular ω . Novamente, a velocidade angular é zero nos extremos do movimento passando por um máximo em algum ponto dele.

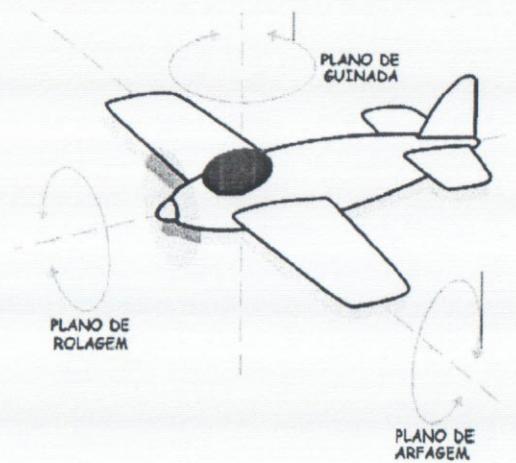


Figura 41. Principais planos de movimentação do avião (SOUZA, 1999).

O tratamento para o caso de deslocamento angular no eixo de arfagem é similar. Supõe-se, no caso geral, que o avião se desloca do ângulo ϕ_1 até o ângulo ϕ_2 com uma velocidade angular ω radianos/s. D_s é o deslocamento linear no solo correspondente à variação no ângulo de visada da câmera. Para o deslocamento considerado têm-se as seguintes relações:

$$D_s = A * \operatorname{tg}(\phi_2) - A * \operatorname{tg}(\phi_1) = A * (\operatorname{tg}(\phi_2) - \operatorname{tg}(\phi_1))$$

$$\phi = \int \omega * dt$$

Para $\omega = \text{constante}$ (válido se $\phi_1 \approx \phi_2$) e integrando $\phi = \int \omega * dt$ têm-se:

$$\phi = \omega * t = 2 * \pi * f * t = \frac{2 * \pi * t}{T}$$

onde: f = freqüência em Hertz; T = período em segundos; $\phi_2 = \phi_1 + \omega * t$.

Supondo que $t_1 = 0$ (instante inicial) e $t_2 = t$ e fazendo o deslocamento D_s igual à metade do comprimento de um pixel, tem-se:

$$D_s = \frac{C_p}{2} = \frac{h}{2Ph} = \frac{K_1 A}{2Ph} \Rightarrow \operatorname{tg}(\phi_1 + \omega * t) = \frac{K_1}{2Ph} + \operatorname{tg}(\phi_1).$$

Observa-se que o tempo não depende da altitude do avião e, para facilitar a análise, supõe-se que o avião está inicialmente nivelado, ou seja, $\phi_1 = 0$. Neste caso,

$$t = \frac{\operatorname{arctg}(K_1 / 2Ph)}{\omega} \Rightarrow t = \frac{\operatorname{arctg}(K_3)}{\omega}$$

O tempo de abertura do obturador depende apenas do inverso da velocidade angular. Em geral, recomenda-se utilizar uma velocidade de obturador de 1/3000 seg e 400 ASA, por causa de vibração. Porém, em dias nublados e escuros, esta velocidade deve ser menor. Se for câmera digital, optar por câmeras de 6 Mpixels ou superior.

A altitude média de vôo, para aplicações em Ciência do Solo, deve ser de 100 m para a maioria dos estudos. Dependendo do que se deseja cobrir no imageamento, podem-se utilizar diferentes lentes possibilitando assim maior ou menor área imageada. Nas Tabelas 1 e 2, se têm exemplos de áreas imageadas em função da altitude de vôo. Uma vez tomado o cuidado com o ajuste de velocidade de obturador e posição da aeronave, o próximo passo é salvar a imagem e a respectiva coordenada.

Uma forma simples de salvar os dados e as coordenadas é através de um programa em pocketPC para controle da câmera e armazenamento das coordenadas GPS, como no sistema FieldAgro® desenvolvido na Embrapa Instrumentação, onde as imagens são armazenadas diretamente nas câmeras digitais utilizadas através de cartões de memória Flash e a coordenada fornecida pelo GPS no instante de captura da imagem, no pocketPC. Depois através de um aplicativo que lê as imagens do cartão,

junta-se no cabeçalho das mesmas a informação de coordenada. Estes aplicativos são aplicativos gratuitos e estão disponíveis para uso.

A obtenção das imagens segue um processo de amostragem. A idéia do método de análise das imagens para estudo da cobertura do solo é fazer a interpretação automática do conteúdo da imagem e gerar os índices correspondentes em forma de mapa.

Atribuindo-se uma escala de cores do menor ao maior índice, pode-se visualizar mais facilmente onde são os pontos com valores maiores, ou menores, ao invés de montar um mosaico com as imagens originais. Além disso, para um mosaico, é necessária uma cobertura completa da área, o que torna o uso de imagens aéreas inviável pelo custo e trabalho necessário.

Com uma grade de amostragem, se programa para obter uma foto dentro de cada quadrícula da grade que representa a amostra da quadrícula toda, conforme pode ser visto na Figura 42.

Tabela 1. Altitudes e áreas imageadas com uma lente de 50 mm.

Altitude (m)	Pixel (cm)	Tamanho da projeção no solo (m)		Área imageada (ha)
		X	Y	
50	0,64	22,20	14,80	0,03
100	1,28	44,40	29,60	0,13
150	1,93	66,60	44,40	0,30
200	2,57	88,80	59,20	0,53
250	3,21	111,00	74,00	0,82
300	3,85	133,20	88,80	1,18
350	4,50	155,40	103,60	1,61
400	5,14	177,60	118,40	2,10
450	5,78	199,80	133,20	2,66
500	6,42	222,00	148,00	3,29
600	7,71	266,40	177,60	4,73
700	8,99	310,80	207,20	6,44
800	10,28	355,20	236,80	8,41
900	11,56	399,60	266,40	10,65
1000	12,85	444,00	296,00	13,14

Tabela 2. Altitudes e áreas imageadas com uma lente de 28 mm.

Altitude (m)	Pixel (cm)	Tamanho da projeção no solo (m)		Área imageada (ha)
		X	Y	
50	1,15	39,64	26,43	0,10
100	2,29	79,29	52,86	0,42
150	3,44	118,93	79,29	0,94
200	4,59	158,57	105,71	1,68
250	5,74	198,21	132,14	2,62
300	6,88	237,86	158,57	3,77
350	8,03	277,50	185,00	5,13
400	9,18	317,14	211,43	6,71
450	10,32	356,79	237,86	8,49
500	11,47	396,43	264,29	10,48
600	13,76	475,71	317,14	15,09
700	16,06	555,00	370,00	20,54
800	18,35	634,29	422,86	26,82
900	20,65	713,57	475,71	33,95
1000	22,94	792,86	528,57	41,91

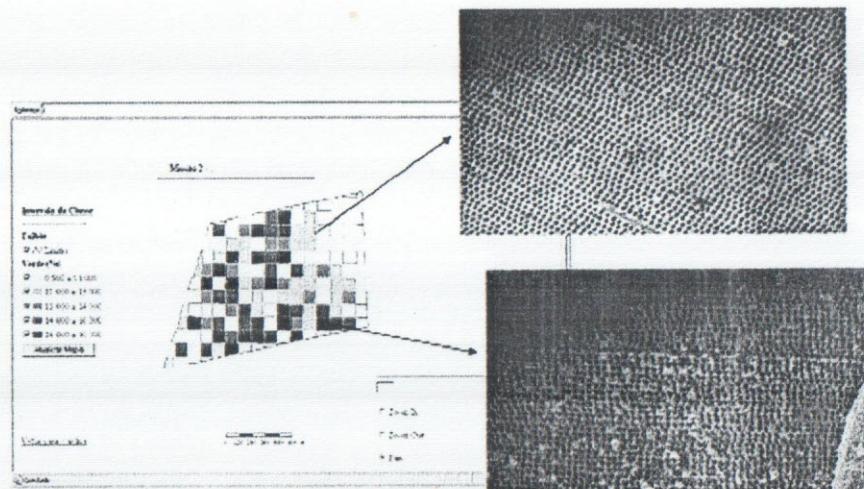


Figura 42. Grade de amostragem de imagens e exemplos de imagens amostradas numa área de eucalipto, com diferentes coberturas de solo.

Pré-processamento das imagens

Os pré-processamentos já descritos na introdução ao processamento de imagens devem ser utilizados para corrigir imagens em diferentes condições climáticas, altitudes e em diferentes tipos de cultura, falta de nitidez devido à vibração na aeronave, falta de foco devido às condições de luz, inclinação inadequada para trabalhos de monitoramento. No pré-processamento, de uma forma geral, utilizam-se algoritmos para suavizar ruídos na imagem, separação de imagens fora das especificações desejadas de altitude, inclinação e iluminação. Quando se tem uma imagem em outras bandas espectrais, como no infravermelho (Figura 43), o que se faz é decompor as diferentes bandas e calcular os respectivos índices de cobertura mais utilizados na literatura.

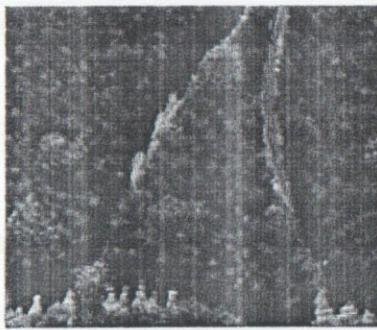


Figura 43. Imagem de cultura de eucalipto com infravermelho.

Processamento das imagens

O processamento das imagens pode diferir dependendo dos objetivos, tais como: mapeamento de plantas invasoras; densidade de palha sobre o solo; zoneamento de solos e de áreas homogenias de manejo; drenagem natural da parcela; amostragem de solo orientada; crescimento e desenvolvimento da cultura até à maturação; dentre outras. Todos estes podem ser atingidos dependendo do tipo de câmera utilizada e da resposta espectral da mesma. Além disso, cada aplicação pode necessitar de um processamento específico e este processamento não pode ser generalizado para todas as possíveis aplicações. Porém, normalmente se trabalha com imagens coloridas para identificar diferenças por cor e textura na imagem. Assim, os métodos de segmentação por cor são os mais utilizados.

O estudo da cobertura do solo pode gerar uma grande quantidade de imagens para serem processadas. Assim, o método mais utilizado devido à velocidade de processamento e capacidade de aprendizado é a segmentação por redes neurais artificiais, e a mais simples delas, e bem difundida, é a MLP já descrita anteriormente. Na Figura 44, tem-se o caso de uma cultura de cana-de-açúcar onde se evidencia o que é cana soca, palha sobre o solo e o solo descoberto através de uma MLP.

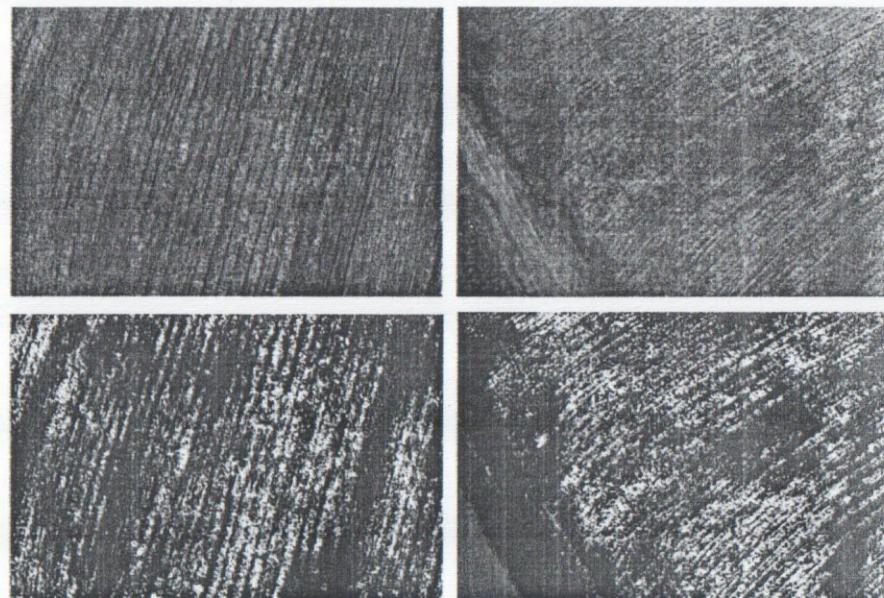


Figura 44. Análise de imagens de cana-de-açúcar identificando áreas de cana (azul), palha (amarelo) sobre o solo e solo descoberto (marrom).

Na Figura 45, pode ser visualizado o resultado do treinamento da rede neural para segmentação da imagem de citros, separando a cobertura sobre o solo e o solo descoberto. Neste caso, é interessante verificar que algumas das plantas de citros apresentam coloração e foram detectadas de forma diferente. Na Figura 46, o mesmo tipo de processamento e treinamento da rede neural foi feito para uma cultura de soja. Neste caso, visualiza-se o resultado da segmentação da imagem em área de soja, doenças, plantas invasoras e solo descoberto.



Figura 45. Análise de imagens de citros (verde) identificando áreas de palha sobre o solo (azul) e solo descoberto (vermelho).

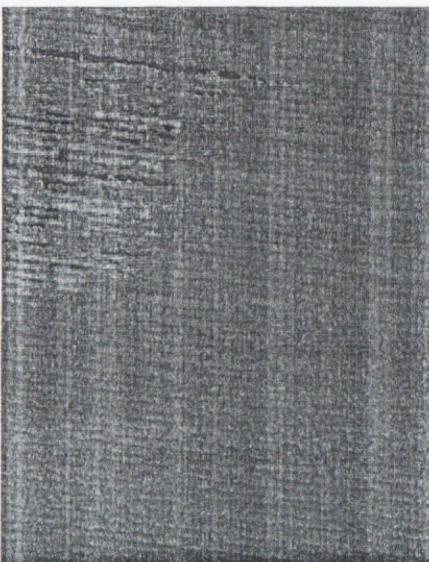
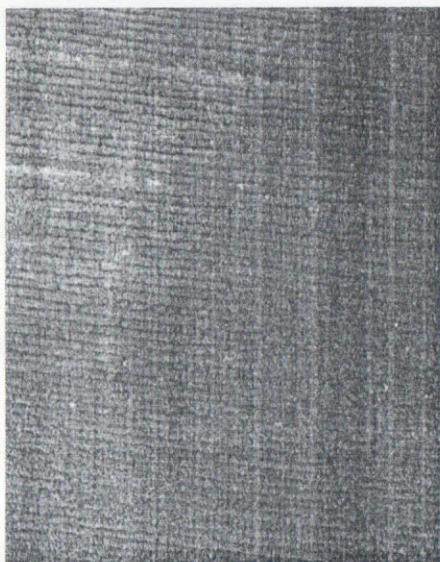


Figura 46. Análise de imagens de soja identificando áreas de soja, doenças, plantas invasoras e solo descoberto.

No caso de uma cultura de milho com 15 dias, pode ser visto na Figura 47 os resultados do processamento identificando palha sobre o solo, solo descoberto, plantas invasoras e a própria cultura principal.



Figura 47. Análise de imagens de milho com 15 dias, identificando, palha sobre o solo (preto), solo descoberto (vermelho), a cultura (verde) e plantas invasoras (amarelo).

Uma vez processada cada imagem obtida, calculadas as áreas em porcentagem de cada uma das classes em estudo, ou seja, porcentagem de palha sobre o solo, de solo exposto, da cultura principal, de pragas etc, monta-se uma tabela para cada imagem com as respectivas porcentagens.

Estas porcentagens são os índices de cada classe por imagem. Com estes índices e as respectivas coordenadas das imagens, utiliza-se um software de geo-processamento para geração dos mapas para todo o talhão ou toda a propriedade. Em geral, para vôos a 100 m de altura, são obtidas quatro imagens por hectare monitorado.

Além das porcentagens determinadas para cada tema na imagem, pode-se processar cada uma delas para determinar número de plantas por área ou por unidade linear, tamanho de copa, e taxas de uniformidade, regularidades de linhas, etc. Os dados obtidos podem ser transformados em mapas, depois de processadas todas as imagens.

Existem processamentos específicos para cultura e cada fase de desenvolvimento da lavoura. Na seqüência são apresentados alguns exemplos de processamento, que permitem maior confiabilidade das informações (aumento no número de amostragens), agilidade, com a possibilidade de mudanças durante a safra, obtenção de dados para planejamento futuro, localizar as oportunidades na lavoura permitindo análise e ações no momento adequado, geração de mapas e relatórios de acordo com temas, ferramenta de gestão que proporciona auxílio na tomada de decisão gerencial e melhora na produtividade de equipes e histórico.

Na cultura de cana-de-açúcar podem ser interessantes as determinações de falha no plantio, regularidade de linha, alterações ou manchas na área, palha, solo exposto e cultura. Sendo o critério mais utilizado de determinação de falha uma metodologia de avaliação, a ausência de cultura na linha de plantio com distância superior a 50 centímetros.

Na área florestal a contagem de plantas é fundamental, bem como as identificações de falhas de plantio, regularidade de linhas e inventário de sobrevivência. Um exemplo de processamento para contagem de plantas de eucalipto é apresentado na Figura 48. Na citricultura, a contagem de plantas é sempre de grande interesse e pode ser visto na Figura 49, bem como alteração no dossel superior, porcentagem de solo exposto, aplicação localizada.

A contagem de plantas em linhas é útil também em culturas anuais como o milho, e pode ser identificado como apresentado na Figura 50.

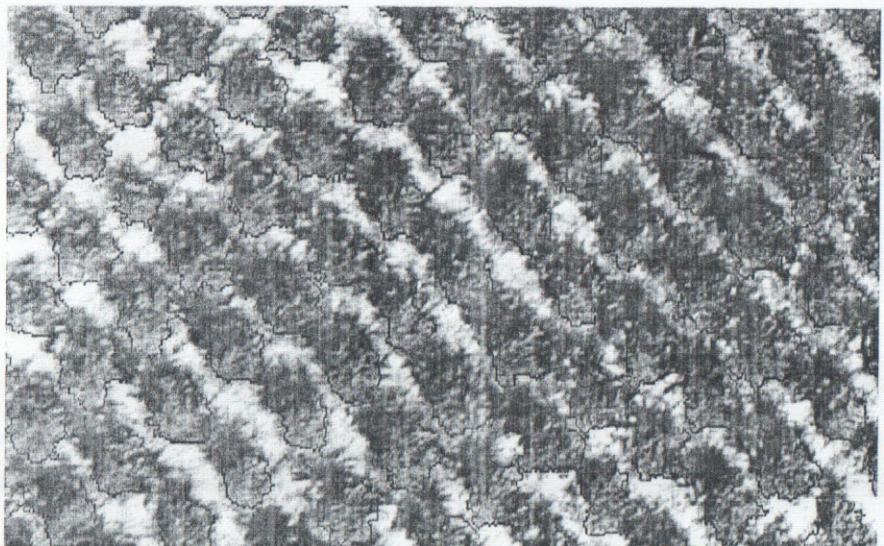


Figura 48. Contagem de plantas de eucalipto, identificando tamanho de copa

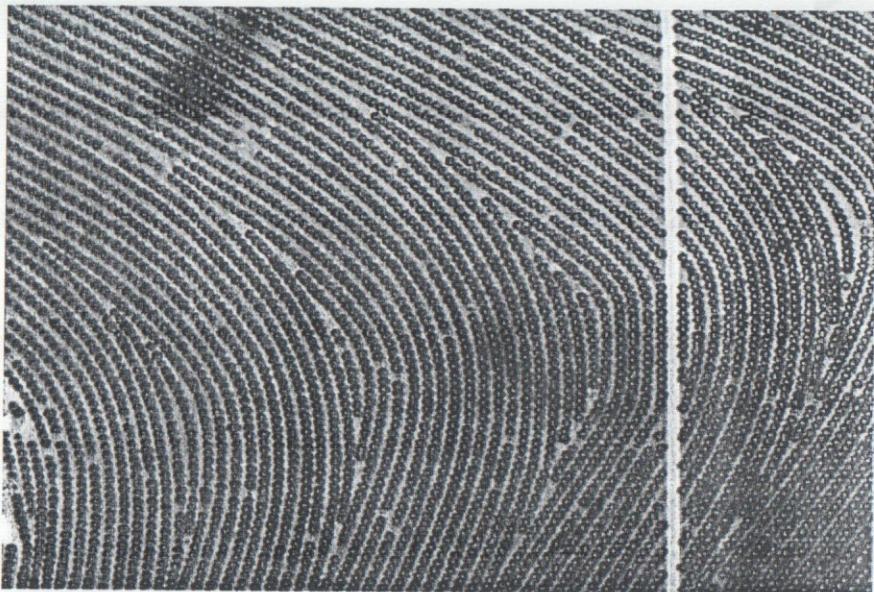


Figura 49. Contagem de plantas de citros

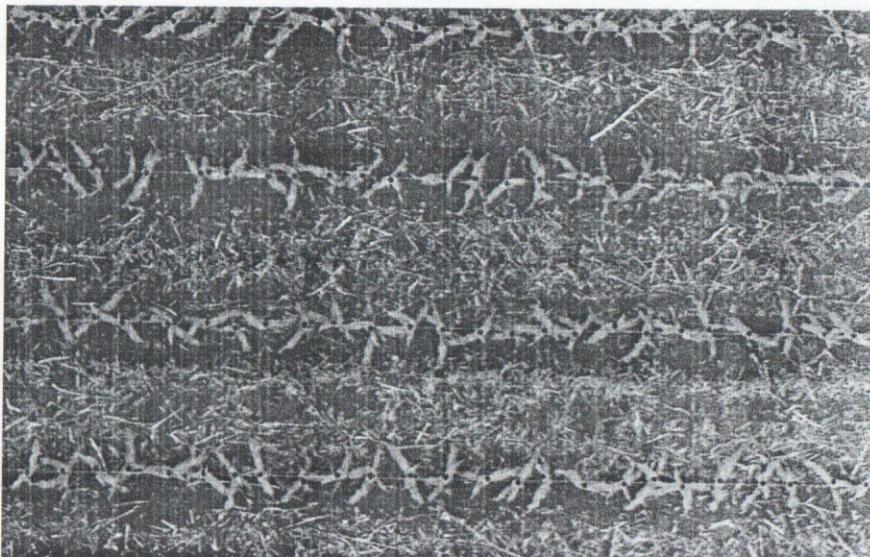


Figura 50. Contagem de plantas por metro em linhas de plantio de milho

Geração de mapas temáticos e estatísticos

A geração de mapas utiliza dois tipos de mapas, os temáticos e os estatísticos. Os mapas temáticos são os mapas dos índices obtidos no processamento. Para cada tema de estudo se tem um mapa do talhão ou da propriedade como um todo. Estes mapas podem ser gerados através de softwares como o MapInfo, Spring, dentre outros.

Um exemplo de mapa de índices pode ser visto na Figura 51. Neste mapa se tem um exemplo de mapa temático para a cultura do milho com 15 dias, sendo que o índice de cobertura verde sobre o solo varia de 0 (branco) a 100% (verde escuro). Uma vez que se tenha o mapa temático, identificam-se as regiões homogêneas medindo a variação espacial de cada região, gerando-se os mapas geoestatísticos. O monitoramento com base nos mapas geoestatísticos não permite que se identifiquem as diferentes áreas de cobertura do solo segundo um critério de divisão em classes distintas sem levar em consideração a correlação espacial entre os valores. A maioria das técnicas de divisão em classes utiliza Análise de Regressão sem um critério espacial, com a análise isolada de cada ponto no espaço.

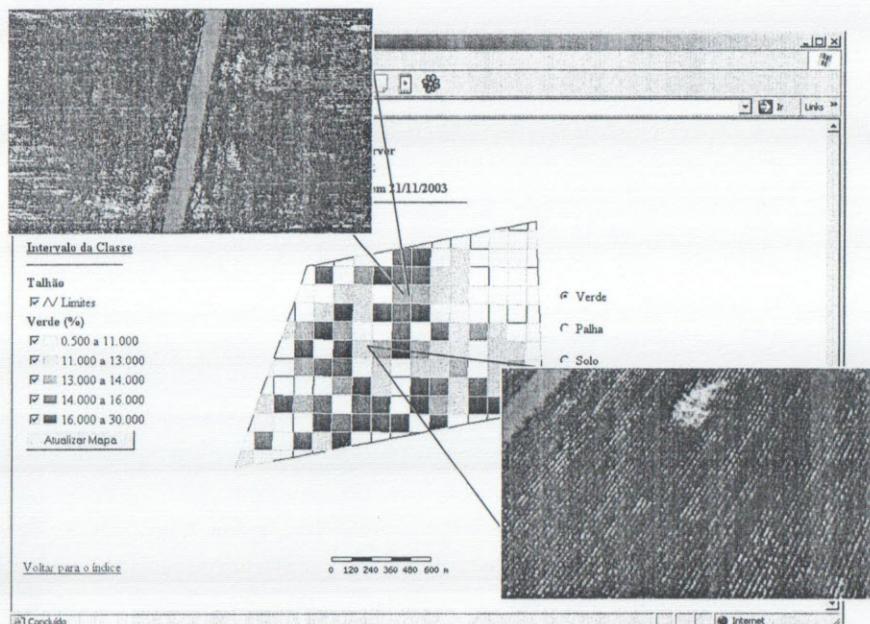


Figura 51. Mapa temático da cobertura do solo pela cultura de milho com 15 dias.

Os mapas geoestatísticos visam a identificação de áreas com variações especiais. Uma forma simples e eficiente de abordagem geoestatística pode ser feita utilizando o critério de Controle Estatístico de Processos comumente utilizado no seguimento industrial. Este critério fundamenta-se na correlação espacial entre os valores de índices, onde as áreas com variações especiais são consideradas como regiões de um talhão agrícola com características diferentes da média encontrada no talhão, circundada por n regiões similares. Esta região, formada por células de resolução espacial pré-definida, apresenta valores de índices acima (potencial) ou abaixo (problema) da média dos valores apresentados no talhão resultando em um mapa de zonas homogêneas denominado de mapa de variações, ou mapa geoestatístico.

De acordo com a teoria da variabilidade (DEMING, 1990), pode-se incorrer em dois erros quando se pretende melhorar um determinado processo: tratar como causa especial qualquer falha, quando realmente essa deficiência é procedente de causa comum; e atribuir a causas comuns qualquer falha, quando realmente essas deficiências são precedentes de uma causa especial.

Neste contexto, aplicando-se o processo estatístico em índices de cobertura do solo das imagens, são gerados mapas de zonas homogêneas, de acordo com a correlação espacial dos dados, denominados de mapas de variações ou mapas estatísticos. Uma anormalidade potencial é quando o valor da região é maior que a média adicionada do desvio padrão do talhão, para uma região de pelo menos n vizinhos e uma anormalidade problema é quando o valor da região é menor que a média adicionada do desvio padrão do talhão.

Como exemplo todo o processo é aplicado no monitoramento de falhas de plantio na cultura de cana-de-açúcar. Na primeira etapa foram selecionados dois talhões apresentados na Figura 52. Foi efetuado o planejamento de vôo e foram obtidas as imagens nas respectivas localizações apresentadas. Alguns exemplos das imagens nos talhões e os respectivos processamentos podem ser visualizados na Figura 53.

Uma vez adquiridas as imagens, estas foram processadas de tal forma a gerar os seguintes mapas de índices de ocorrências:

- *Cultura*: indica como está a distribuição da cultura no talhão em termos de porcentagem nas fotos (Figuras 54a e 54b);

- *Solo nu*: indica quanto de solo está exposto na foto, em termos de porcentagem. Inclui neste caso as falhas e os espaços vazios entre as linhas de plantio;

- *Palha*: indica a porcentagem de palha sobre o solo que está visível na imagem;

Em seguida, a partir dos índices gerados nos mapas temáticos foram montados os mapas estatísticos, conforme Figura 54. O solo nu é classificado como:

- *Normal*: solo exposto com distribuição normal;

- *Oportunidade*: área onde se tem solo exposto mais fortemente e pode ser um determinante de falha;

- *Problema*: áreas onde a cultura cobre mais o solo;

A palha é classificada como:

- *Normal*: palha dentro de uma distribuição normal;

- *Oportunidade*: áreas onde a palha está concentrada;

- *Problema*: áreas onde a palha está mal distribuída;

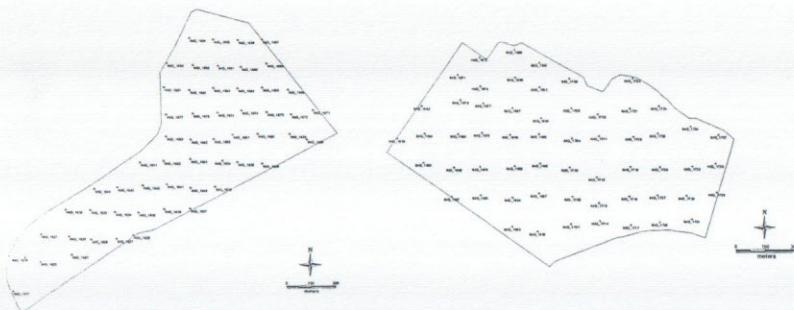


Figura 52. Talhões de 130 ha e as respectivas localizações das imagens.

Uma vez identificada a área de interesse no mapa estatístico, ou seja, a área de oportunidades, sugere-se carregar as coordenadas desta área e ir até o local para possíveis tomadas de decisão. Uma forma de ir até o local seria utilizando um computador portátil, ou PDA, com GPS, para ajudar na navegação. Dependendo do tipo de cultura, de estudo e de investigação da área, sugere-se fazer amostragens de solo, de folhas, medidas de clorofila ou uma simples inspeção.

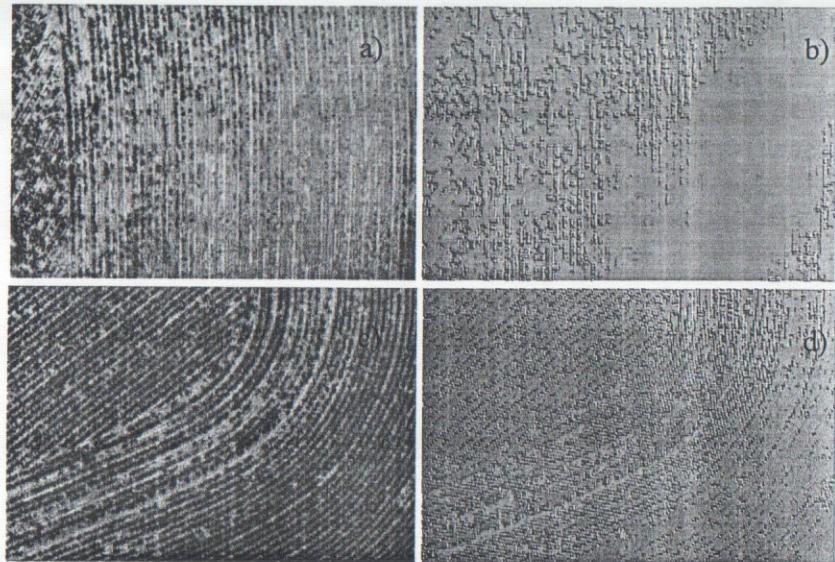


Figura 53. Exemplos de imagens tiradas nos talhões da Figura 52 e o respectivos processamentos.

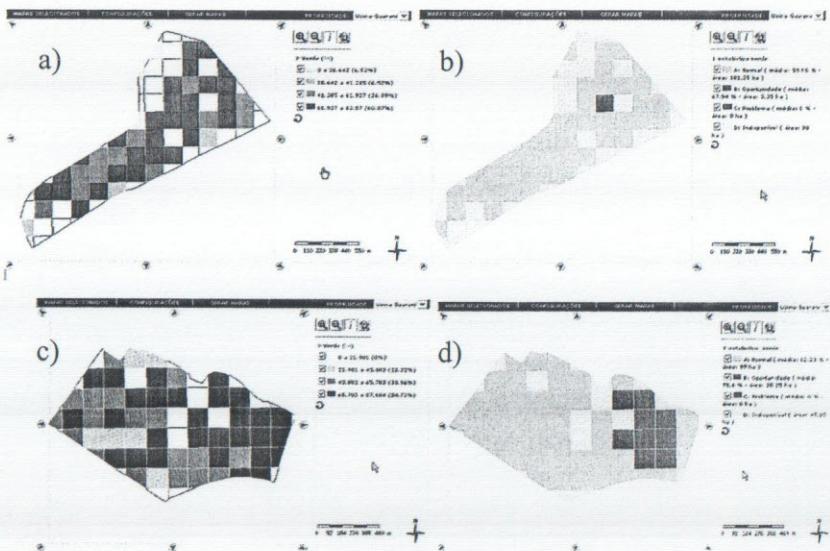


Figura 54. Mapas temáticos da cultura de milho com 15 dias: a) Mapa temático talhão da Figura 52a e (b) o mapa estatístico; (c) Mapa temático do talhão da Figura 52b e o (d) mapa estatístico apresentando uma área de oportunidades.

Referências

- ABI SAAB, O. J. G.; RALISCH, R.; MEDINA, C. C.; JORGE, L. A. C.; TRIBULATTO, M. C.; SILVA JÚNIOR, D. A. Effect of four levels of liming on an alic soil on the root development of corn (*Zea mays L.*). 8 p. In: INTERNATIONAL SYMPOSIUM ON PLANT-SOIL INTERACTIONS AT LOW PH, 4., 1996, Belo Horizonte. **Proceedings...** Sete Lagoas: [s. n.], 1996.
- ANDRADE, A. O.; MARTINS, W. **Redes neurais aplicadas ao processamento de imagens de satélite.** Disponível em: <<http://www.eee.ufg.br/paper.html>>. Acesso em: 01 abr 2001.
- ARRUDA, F. B. Determinação da cobertura do solo durante o ciclo das culturas. **R. bras. Ci. Solo**, Campinas, v. 8, p. 145-150, 1984.
- ARSENAULT J.-L.; POULEUR, S.; MESSIER, C.; GUAY, R. WinRHIZO, a root-measuring system with a unique overlap correction method. **HortScience**, Alexandria, v. 30, p. 906, 1995. (Abstract).
- BARBOSA, L. C. P. **SINACOM: Sistema de Navegação e Controle de Manobras do Projeto ARARA.** 2000. 55 f. mini-dissertação para qualificação ao mestrado defendida no ICMC, Universidade de São Paulo, São Carlos.
- BASSOI, L. H.; ASSIS, J. S. Considerações sobre a utilização dos métodos do perfil auxiliado pelo processamento de imagens digitais e do monolito, na análise da distribuição de raízes no solo. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA-SIAGRO, 1., 1996, São Carlos-SP. **Anais...** São Carlos: EMBRAPA-CNPDIA, 1996.
- BASSOI, L. H.; FANTE JÚNIOR, L.; JORGE, L. A. C.; CRESTANA, S.; REICHARDT, K. Distribuição do sistema radicular do milho irrigado em terra roxa estruturada latossólica: I: comparação de metodologias. **Scientia Agricola**, Piracicaba, v. 51, n. 3, p. 513-518, set./dez. 1994a.
- BASSOI, L. H.; FANTE JÚNIOR, L.; JORGE, L. A. C.; CRESTANA, S.; REICHARDT, K. Distribuição do sistema radicular do milho irrigado em terra roxa estruturada latossólica: II: comparação entre cultura irrigada e fertirrigada. **Scientia Agricola**, Piracicaba, v. 51, n. 3, p. 541-548, set./dez. 1994b.
- BATISTA NETO, J. E. S. **Techniques for computer-based anatomical segmentation of the Brain using MRI.** 1996. Thesis. University of London, London.
- BOHM, W. **Methods of studying root systems.** New York: Springer-Verlag, 1979. 194 p.
- BRITO JÚNIOR, A. M. **Separação de cores em uma imagem via transformada de Hotelling.** Campinas: UNICAMP, 1995. 13 p. Projeto final de Computação Gráfica.
- CAMPBELL, N. W.; MACKEOWN, W. P. J.; THOMAS, B. T.; TROSCIANKO, T. The automatic classification of outdoor images. In: BRITISH MACHINE VISION CONFERENCE. 1995, Birmingham, UK. **Proceedings...** [S. l.:s. n.], 1995a. p. 297-306.
- CAMPBELL, N. W.; THOMAS, B. T.; TROSCIANKO, T. Neural networks for the segmentation of outdoor images. In: ENGINEERING APPLICATIONS OF NEURAL NETWORKS, 1996, London. **Proceedings...** [S. l.:s. n.], 1996.
- CAMPBELL, N. W.; THOMAS, B. T.; TROSCIANKO, T. Segmentation of Natural Images using Self-Organizing Feature Maps. In: BRITISH MACHINE VISION CONFERENCE, 1995, Birmingham, UK. **Proceedings...** [S. l.:s. n.], 1995b.
- CAREVIC, D.; CAELLI, T. Region-based coding of color images using Karhunen-Loeve transform. **Graphical Models and Image Processing**, Orlando, v. 59, n. 1, p. 27-38, Jan. 1997.
- CARVALHO, A. C. P. L. F. **Redes neurais:** notas de aula. São Carlos: ICMC-USP, 1999. (Notas didáticas..., n.32).
- CINTRA, F. L. D.; NEVES, C. S. V. J. Aspectos metodológicos do estudo do sistema radicular de plantas perenes através de imagens. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Campinas, v. 21, n. 3, set./dez. 1996.
- CINTRA, F. L. D. Equipamento com macaco hidráulico para estudo do sistema radicular. In: WORKSHOP SOBRE SISTEMA RADICULAR: METODOLOGIAS E CASOS, 1., 1999, Aracajú, SE. **Anais...** Aracajú: EMBRAPA-Tabuleiros Costeiros, 1999. p. 283-287.
- COGO, N. P.; AMADO, T. J. C. Avaliação da exatidão do método fotográfico utilizado na determinação da porcentagem de cobertura por resíduos culturais. In: CONGRESSO BRASILEIRO DE CONSERVAÇÃO DO SOLO, 6., 1986, Campo Grande. **Resumos...** Campinas: Fundação Cargill, 1986. p. 98.

COSTA, L. F.; CESAR-JÚNIOR., R. M. **Shape analysis and classification – Theory and Practice**. Boca Raton: CRC Press, 2001. 659 p.

CRESTANA, S.; GUIMARÃES, M. F.; JORGE, L. A. C.; RALISCH, R.; TOZZI, C. L.; TORRE-NETO, A.; VAZ, C. M. P. Avaliação da distribuição de raízes no solo auxiliada por processamento de imagens digitais. **Revista brasileira de ciência do solo**, Campinas, v. 18, n. 3, p. 365-371, set./dez. 1994.

CURMI, P.; KERTZMAN, F. F.; QUEIROZ NETO, J. P. Degradation of structure and hydraulic properties in an oxisol under cultivation (Brazil). In: **INTERNATIONAL WORKING MEETING ON SOIL MICROMORFOLOGY**, 9., 1992, Townsville, Queensland, Austrália. **Proceedings...** [S. l.:s. n.], 1992.

DEMING, W. E. **Qualidade: a revolução da administração**. Rio de Janeiro: Marques-Saraiva, 1990. Trad. Fancis Henrik Aubert et all.

DURRET, H. J. **Color and the computer**. Orlando: Academic Press, 1987.

ELWELL, H. A.; GARDNER, S. **Comparison of two techniques for measuring percent crop canopy cover of row crops in erosion research programmes**. Rhodesia, Salisbury: Department of Soil Conservation and Extension, 1976. 20 p. (Research Bulletin, 19).

ELWELL, H. A.; STOCKING, M. A. Vegetal cover to estimate soil erosion hazard in Rhodesia. **Geoderma**, Amsterdam, v. 15, p. 61-70, 1976.

ELWELL, H. A.; WENDELAAR, F. E. **To initiate a vegetal cover data bank for soil loss estimation**. Harare: Department of Conservation and Extension, Institute of Agricultural Engineering, 1977. 42 p. (Research Bulletin, 23).

EMBRAPA – Centro Nacional de Pesquisa e Desenvolvimento de Instrumentação Agropecuária (São Carlos, SP). Lúcio André de Castro Jorge, Silvio Crestana. **Sistema integrado para análise de raízes e cobertura do solo - SIARCS**. BR NPI 004276. Patente requerida em dez. 1996.

FACON, J. **Morfologia Matemática: teoria e exemplos**. Curitiba: PUC, 1996.

FANTE-JÚNIOR, L.; JORGE, L. A. C.; REICHARDT, K.; CRESTANA, S. Avaliação do sistema radicular por diferentes métodos. In: **REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA**, 10., 1994, Florianópolis. Pequena propriedade X desenvolvimento sustentável. **Resumos...** Florianópolis: Sociedade Brasileira de Ciência do Solo, 1994. p. 318-319. ref. 104.

GIACINTO, G.; ROLI, F.; BRUZZONE, L. Combination of neural and statistical algorithms for supervised classification of remote-sensing images. **Pattern Recognition Letters**, Amsterdam, v. 21, p. 385-397, 2000.

GOMES, J.; VELHO, L. **Computação gráfica: imagem**. [S. l.]: IMPA-SBM, 1994.

GONG, Y.; SAKAUCHI, M. Detection of regions matching specified chromatic features. **Computer Vision and image Understanding**, San Diego, v. 61, n. 2, p. 263-269. Mac. 1995.

GONZALEZ, R. C.; WINTZ, P. **Digital Image Processing**. Reading: Addison Wesley, 1987.

GREENLAND, D. J. The physics and chemistry of the soil-root interface: some comments. In: HARLEY, J. L.; RUSSEL, R. S. **The soil-root interface**. New York: Academic Press, 1979. p. 83-98.

GUIMARÃES, M. F.; JORGE, L. A. C.; DE MARIA, I. C.; TAVARES FILHO, J.; BICUDO, S. J.; CRESTANA, S. Três metodologias de avaliação de raízes: descrição, limitações e vantagens. In: **SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA-SIAGRO**, I., 1996, São Carlos-SP. **Anais...** São Carlos: EMBRAPA-CNPDA, 1996.

HARALICK, R. M.; SHAPIRO, L. G. **Computer and Robot Vision**. Reading: Addison-Wesley, 1992.

HARWIG, R. O.; LAFLEN, J. M. A meterstick method for measuring crop residue cover. **Journal of Soil and Water Conservation**, Ankeny, v. 33, n. 2, p. 90-91, 1978.

IVO, W. M. Monólito com Placas de Pregos. In: **WORKSHOP SOBRE SISTEMA RADICULAR: METODOLOGIAS E CASOS**, 1., 1999, Aracajú, SE. **Anais...** Aracajú: EMBRAPA-Tabuleiros Costeiros, 1999. p. 269-274.

JAIN, A. K. **Fundamentals of digital image processing**. Englewood Cliffs: Prentice-Hall International Editions, 1989.

JAIN, A. K.; VAILAYA, A. Image retrieval using color and shape. **Pattern Recognition**, Ezmsford, v. 29, n. 8, p. 1233-1244, 1996.

JESUS, A. **Uma abordagem morfológica para segmentação de logotipos em cheques bancários brasileiros sem conhecimento a priori**. 1999. Dissertação (Mestrado) – Pontifícia Universidade Católica, Curitiba.

JONG VAN LIER, Q.; SPAROVEK, G.; VASQUES FILHO, J. Análise de imagens utilizando um "scanner" manual: aplicações em agronomia. **Revista brasileira de Ciência do Solo**, Campinas, v. 17, p. 479-482, 1993.

JORGE, L. A. C. Descrição detalhada do método de trincheira com produção de imagens para uso de SIARCS®. In: **WORKSHOP SOBRE SISTEMA RADICULAR: METODOLOGIAS E CASOS**, 1., 1999, Aracajú, SE. **Anais...** Aracajú: EMBRAPA-Tabuleiros Costeiros, 1999. p. 255-267.

JORGE, L. A. C. **Determinação da cobertura do solo em fotografias aéreas do Projeto ARARA**. 2001. 97 f. Dissertação (Mestrado) - ICMC-USP, Universidade de São Paulo, São Carlos, SP.

JORGE, L. A. C.; CRESTANA, S. **Recomendações práticas para utilização do SIARCS 3.0 nos estudos de raízes, cobertura vegetal, folhas e outras aplicações**. São Carlos, SP: EMBRAPA-CNPDIA, 1996. 34 p. (EMBRAPA-CNPDIA. Recomendação Técnica, 4).

JORGE, L. A. C.; DE MARIA, T. C.; LOMBERDI NETTO, F.; CRESTANA, S. Avaliação da cobertura do solo por culturas através de processamento de imagens. In: **CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO**, 24., 1993, Goiânia. Cerrados: fronteira agrícola no século XXI. **Resumo...** Goiânia: SBCS, 1993. p. 139-140. v. 3.

JORGE, L. A. C.; GUIMARÃES, M. F.; ABI SAAB, O. J. G.; RALISCH, R.; MEDINA, C. C.; CRESTANA, S. Estudo da influência da calagem de solos ácidos no sistema radicular do milho (*Zea mays L.*), auxiliado por processamento de imagens. In: **CONGRESSO NACIONAL DE MILHO E SORGO**, 21., 1996, Londrina. **Resumos...** Londrina: [s. n.], 1996a. p. 139.

JORGE, L. A. C.; MACEDO, A.; GUIMARÃES, M. F.; MARTINS, M. D. C. Mathematical morphology applied to soil pore and aggregate

characterization. In: **WORLD CONGRESS OF COMPUTERS IN AGRICULTURE AND NATURAL RESOURCES**, 2001, Iguaçu Falls. **Proceedings...** St. Joseph: American Society of Agricultural Engineers, 2001. p. 36-41. Edited by Fedro Zazueta, Jiannong Xin.

JORGE, L. A. C.; RALISCH, R.; ABI SAAB, O. J. G.; MEDINA, C. C.; GUIMARÃES, M. F.; NEVES, C. S. V. J.; CRESTANA, S.; CINTRA, F. L. D.; BASSOI, L. H.; FERNANDES, S. B. V. Aquisição de imagens de raízes. In: JORGE, L. A. C. (Ed.). **Recomendações práticas para aquisição de imagens digitais analisadas através do SIARCS**. São Carlos: EMBRAPA-CNPDIA, 1996b. p. 2-28. (EMBRAPA-CNPDIA. Circular Técnica, 1).

JORGE, L. A. C.; **Recomendações práticas para aquisição de imagens digitais analisadas através do SIARCS®** São Carlos, SP: Embrapa CNPDIA, 1996. 57 p. (EMBRAPA-CNPDIA. Circular Técnica, 01).

JORGE, L. A. C.; SOUZA, N. P.; TRINDADE JR., O.; TOZZI, C. L.; NETO, A. T. Studies of Soil Conservation for Precision Farming by Digital Color Image Analysis. In: **ASAE/CSAE-SCGR ANNUAL INTERNATIONAL MEETING**, 1999, Toronto. **Proceedings...** Toronto, Ontario Canadá: [s. n.], 1999. (CD-ROM).

JORGE, L. A. C.; TRINDADE JÚNIOR, O. **Metodologia para utilização de aeromodelos em monitoramento aéreo**. São Carlos, SP: Embrapa Instrumentação Agropecuária, 2002. 6 p. (Embrapa Instrumentação Agropecuária. Circular técnica, 15).

KOFFLER, N. F. A profundidade do sistema radicular e o suprimento de água às plantas no cerrado. **Informações agronômicas**, Piracicaba, v. 33, p. 1-4, 1986.

KOPKE, U. Methods for studying root growth. In: RUSSEL, R. C.; IGUE, K.; MEHTA, U. R. **The soil / root systems in relation to brazilian agriculture**. Londrina: IAPAR, 1981. p. 303-318.

LAFLEN, J. M.; COLVIN, T. S. Effect of crop residue on soil loss from continuous row cropping. **Transactions of the ASAE**, St Joseph, v. 24, p. 605-609, 1981.

LIU, J.; WANG, L.; LI, S. Z. MRMRF texture classification and MCMC parameter estimation. IN: **VISION INTERFACE**, Proceedings... Trois-Rivières, Canada, May, 1999.

LIU, X.; WANG, D. L. Range image segmentation using a relaxation oscillator network. **IEEE Transactions on Neural Networks**, New York, v. 10, n. 3, 1999.

LOWERY, B.; LILLESAND, T. M.; MUELLER D. H.; WEILER, P.; SCARPACE, F. L.; DANIEL, T. C. Determination of crop residue cover using scanning microdensitometry. **Journal Soil and Water Conservation**, Ankeny, v. 39, p. 402- 403, 1984.

MATHERON, G. **Random Sets and Integral Geometry**. New York: John Wiley and Sons, 1975.

MATHIAS, E.; CONCI, A. Comparing the influence of color space and metrics in content-based image retrieval. In: SIBGRAPI'98, Oct. 1998, Rio de Janeiro. **Proceedings...** Rio de Janeiro: SBC, 1998. p. 371-378.

MCGREGOR, K. C.; BENGTSON, R. L.; MUTCHEL, C. K. Effects of surface straw on interrill runoff and erosion of grenada silt loam soil. **Transactions. of the ASAE**, St Joseph, v. 31, p. 11-116, 1988.

MEDINA, C. C. **Estudo da aplicação de gesso, calcário e vinhaça na produção e enraizamento da cana-de-açúcar (Saccharum spp)**. 1993. 211 f. Tese (Doutorado) – Faculdade de Ciências Agronômicas, Universidade Estadual, Botucatu.

MEDINA, C. C. Método da trincheira com contagem manual das raízes. In: **WORKSHOP SOBRE SISTEMA RADICULAR: METODOLOGIAS E CASOS**, 1., 1999, Aracajú, SE. **Anais...** Aracajú: EMBRAPA-Tabuleiros Costeiros, 1999. p. 275-281.

MERTEN, G. H.; MIELNICZUK, J. Distribuição do sistema radicular e dos nutrientes em latossolo roxo sob dois sistemas de preparo do solo. **Revista brasileira de ciência do Solo**, Campinas, v. 15, n. 3, p. 363-368, 1991.

MIELNICZUK, J. Importância do estudo de raízes no desenvolvimento de sistemas agrícolas sustentáveis. In: **WORKSHOP SOBRE SISTEMA RADICULAR: METODOLOGIAS E CASOS**, 1., 1999, Aracajú, SE. **Anais...** Aracajú: EMBRAPA-Tabuleiros Costeiros, 1999. p. 13-16.

MOLIN, J. P. Agricultura de precisão. Parte I: O que é estado da arte em sensoriamento. **Engenharia Agrícola**, Sorocaba, v. 17, n. 2, p. 97-107, dez. 1997.

MORAN, M. S.; INOUE, Y.; BARNES, E. M. Oportunities and limitatios for image-based remote sensing in precision crop management. **Remote Sensing of Environment**, New York, v. 61, p. 319-346, 1997.

MOREIRA, J.; COSTA, L. F. Multispectral image segmentation by chromaticity classification. In: **SIBGRAPI**, 8., 1995, Rio de Janeiro. **Anais...** Rio de Janeiro: SBC, 1995. p. 119-125.

MORRISON, J. E.; HUANG, C.; LIGHTLE, D. T.; DAUGHTRY, C. S. T. Residue measurement techniques. **Journal Soil and Water Conservation**, Ankeny, v. 48, p. 478-483, 1993.

NEVATIA, R. Image segmentation. In: YOUNG T. Y.; FU, K. S. **Handbook of pattern recognition and image processing**. London: Academic Press, 1986. p. 215-232. Chapter 9.

OHLANDER, R.; PRICE, K.; REDDY, D. R. Picture segmentation using a recursive splitting method. **Computer Graphics And Image Processing**, New York, v. 8, p. 313-333, 1978.

OHTA, Y.; KANADE, T.; SAKAI, T. Color Information for region segmentation. **Computer Graphics and Image Processing**, New York, v. 13, pp. 222-241, 1980.

OTSU, N. "A Threshold Selection Method from Gray-level Histograms". **IEEE Transactions on Systems, Man and Cybernetics**, New York, v. SMC 9, no 1, pp. 62-66, 1979.

PALMA, E. C.; TRINDADE, JR., O. Uma Aeronave Rádio Controlada para Aplicação na Agricultura – Instrumentação de Bordo. In: **SIMPOSIO DE INICIAÇÃO CIENTÍFICA DA USP**, 7., **Anais...** São Paulo, 1999 (CDROM).

PEARSON, R. W. Significance of rooting pattern to crop production and some problems of root research. In: CARSON, E. W. **The plant root and its environment**. Charlottesville: Univ. Press Virginia, 1974. p. 247-267.

PEREIRA, V. P.; MALHEIROS, E. B.; RAGAZZI, W. L.; ZANON, J. C. Comparação entre alguns métodos fotográficos e o método meterstick, para avaliação de cobertura de resíduos de culturas no solo, com modelos simulados. In: **CONGRESSO BRASILEIRO DE CONSERVAÇÃO DO SOLO**, 6.; 1986, Campo Grande. **Resumo...** Campinas: Fund. Cargill, 1986. p. 99.

PHILIPP, S. Image segmentation: the state of the art. In: BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, 12., 1999, Campinas. **Minicursos/Tutorials...** Campinas: UNICAMP, 1999. 7 p.

PINTO, F. A. C.; REID, J. F.; ZHANG, Q.; NOGUCHI, N. Guidance parameter determination using artificial neural network classifier. In: ASAE/CSAE-SCGR ANNUAL INTERNATIONAL MEETING, 1999, Toronto. **Proceedings...** Toronto, Ontario Canadá: ASAE, 1999. 1 CD-ROM.

PLOTEZE, R. O.; BRUNO, O. M. Estudo e comparação de algoritmos de esqueletonização para imagens binárias. In: CONGRESSO BRASILEIRO DE COMPUTAÇÃO – CBCOMP, 4., 2004. **Anais...** [S. l.: s. n.], 2005. p. 59-64.

ROCHA FILHO, J. da; JORGE, L. A. C.; PRIMAVESI, O.; CRESTANA, S. Distribuição radicular de forrageiras, afetada pela intensidade de manejo, avaliada por análise de imagens digitais. In: CONGRESSO LATINO AMERICANO DE CIÊNCIA DO SOLO, 13., 1996, Águas de Lindóia-SP. Solo suelo 96. **Anais...** Campinas: Sociedade Brasileira de Ciência do Solo, 1996. 5 p. 1 CD-ROM.

SALATA, J. C.; ARMENI, J. C.; DEMATÊ, J. L. L. Influência do tipo de sulcador no desenvolvimento do sistema radicular e produtividade de cana-de-açúcar. **STAB**, Piracicaba, p. 12-18, mar/abr, 1987.

SALLAWAY, M. M.; LAWSON, D.; YULE, D. F. Ground cover during fallow from wheat, sorghum and sunflower stubble under three tillage practices in Central Queensland. **Soil & Tillage Research**, Amsterdam, v. 12, p. 347-364, 1988.

SCHETTINI, R. Multicolored object recognition and location. **Pattern Recognition Letters**, Amsterdam, v. 15, p. 1089-1097, 1994.

SERRA, J. **Image Analysis and Mathematical Morphology**. London: Academic Press, 1982.

SLONEKER, L. L.; MOLDENHAUER, W. C. Measuring the amounts of crop residue remaining after tillage. **Journal Soil and Water Conservation**, Ankeny, v. 32, n. 5, p. 231-236, 1977.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. Florence: PWS Publishing, 1999.

SOUZA, N. P. **Sistemas Alternativos para a Obtenção de Imagens Aéreas e sua Aplicação na Agricultura**. 1999. 124 f. Dissertação (Mestrado) - ICMC-USP, Universidade de São Paulo, São Carlos.

SOUZA, N. P.; TRINDADE JR., O.; JORGE, L. A. C. Uso de Aeronaves Rádio Controladas na Obtenção de Fotografias Aéreas - Resultados Iniciais. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA, 2., 1998, São Carlos, SP. **Anais...** São Carlos: Embrapa Instrumentação Agropecuária, 1998.

STEENHOEK, L.; MISRA, M.; BATCHELOR, W.; DAVIDSON, J. Probabilistic neural networks for segmentation of features in corn kernel images. In: ASAE/CSAE-SCGR ANNUAL INTERNATIONAL MEETING, 1999, Toronto, Ontario Canadá. **Proceedings...** Toronto: ASAE, 1999. 1 CD-ROM.

STOCKING, M. Assessing vegetative cover and management effects. In: LAL, R. (Ed.). **Soil Erosion Research Methods**. Ankeny: Soil and Water Conserv. Soc., 1988. p. 163-185.

STOCKING, M.; ELWELL, H. Vegetation and erosion: a review. **Scottish Geographical Magazine**, Edinburgh, v. 92, p. 4-16, 1976.

SUMMER, M. E. Uso atual do gesso no mundo em solos ácidos. In: SEMINÁRIO SOBRE O USO DO GESSO NA AGRICULTURA, 2., 1992, Uberaba. **Anais...** Brasília, DF: IBRAFOS, 1992. p. 7-36.

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: ASAE/CSAE-SCGR ANNUAL INTERNATIONAL MEETING, 1999, Toronto, Ontario Canadá. **Proceedings...** Toronto: ASAE, 1999. 1 CD-ROM.

TRETEL, E.; JORGE, L. A. C.; LOTUFO, R. Uso do diagrama Size-Intensity para a caracterização de meio poroso. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA, 1., 1996, São Carlos-SP. **Anais...** São Carlos: EMBRAPA-CNPDIA, 1996.

VARGAS, E. C.; ROMERO, R. A. F. **Estudo de modelos de redes neurais para a indexação e recuperação de dados**. São Carlos: ICMC USP, Ago. 2000. n. 44. 32 p. Notas didáticas.

VEHTARI, A.; LAMPINEN, J. Bayesian MLP neural networks for image analysis. **Pattern Recognition Letters**, Amsterdam, v.21, n. 13-14, p. 1183-1191, 2001.

VINCENT, L. Fast Opening Functions and Morphological Granulometries, In: SPIE IMAGE ALGEBRA AND MORPHOLOGICAL IMAGE PROCESSING, 5., 1994, San Diego, CA. Proceedings... [S. l.: s. n.], 1994. v. 2300. p. 256-267.

WILLIAMS, T. H. L. An error analysis of the photographic technique for measuring percent vegetative cover. **Soil Sci. Soc. A.m. J.**, Madison, v. 43, p. 578-582, 1979.

YIN, X.; GUO, D.; XIE, M. Hand image segmentation using color and RCE neural network. **Robotics and Autonomous Systems**, Amsterdam, v. 903, p. 1-17, 2001.

ZHANG, T. Y.; SUEN, C. Y. A fast parallel algorithm for thinning digital patterns. **Communications of the ACM**, New York, v. 27, n. 3, p. 236-239, 1984.