Proceedings of the First Workshop on Applications of Computer Graphics and Image Processing to Agribusiness and Environment

XXI Brazilian Symposium on Computer Graphics and Image Processing

October 12-15, 2008, Campo Grande, MS, Brazil

Edited by

Paulo Cruvinel (Embrapa)
Milton Romero (UFMS)

Índice

Prefácio	ii
Comitê de Programa	į
Revisores	,
Avaliação das técnicas de filtragem de Kalman e suavização Rauch-Tung- Striebel para a melhoria da qualidade de imagens tomográficas de solos agrícolas Marcos A. M. Laia	
Modelo de Visualização 2D e 3D de Imagens Tomográficas de Raios X de Amostras Agrícolas, Baseado em Técnicas de Processamento Paralelo e Realidade Virtual Maurício Fernando Lima Pereira e Leonardo Castro Botega	
Uso de Imagens Digitais em Mensurações de Coeficientes Técnicos Agropecuários Fábio Diniz Rossi, Claudino Andrighetto e Otoniel Geter Lauz Ferreira	2

Prefácio

Bem-vindos ao primeiro Workshop on Applications of Computer Graphics and Image Processing to Agribusiness and Environment (WAGAE) que faz parte do Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI 2008).

O agronegócio brasileiro é um setor da economia com grande capacidade de geração de empregos e movimenta algo em torno de US\$ 200 bilhões por ano. Dentre os seus maiores desafios, encontram-se a busca por melhores índices de produtividade e o atendimento à sustentabilidade ambiental dos sistemas de produção. A agricultura vem apontando para o uso e a difusão de novos métodos e aderência às praticas multidisciplinares com a busca de soluções nas diferentes áreas do conhecimento. Neste contexto, uma série de soluções para os problemas que se apresentam tem sido obtida com base na computação gráfica e no processamento de imagens.

O WAGAE tem por objetivo discutir a construção de soluções para problemas que visem sistemas de suporte às decisões, incluindo modelagem e simulação de agroecossistemas, análise de risco e prescrições de manejo nos níveis cognitivo, analítico e de síntese.

O agronegócio é o setor mais importante da economia da região onde o SIBGRAPI 2008 está sendo realizado e contribui significativamente para a economia do País. Este evento torna-se relevante para o desenvolvimento da área e para o enriquecimento dos pesquisadores e dos estudantes.

Agradecemos aos autores que submeteram trabalhos ao WAGAE e ao Comitê de Programa pela sua substancial contribuição nas avaliações.

Campo Grande, outubro de 2008.

Paulo Cruvinel e Milton Romero

Organização do WAGAE SIBGRAPI 2008

Comitê de Programa

Coordenadores

Paulo Cruvinel (Empresa Brasileira de Pesquisa Agropecuária – Embrapa) Milton Romero (Universidade Federal de Mato Grosso do Sul – UFMS)

Comitê de Programa

Hemerson Pistori (Universidade Católica Dom Bosco – UCDB)
Jacob Scharcanski (Universidade Federal do Rio Grande do Sul – UFRGS)
Joaquim Teixeira de Assis (Universidade Estadual do Rio de Janeiro – UERJ /IPRJ)
José Saito (Universidade Federal de São Carlos – UFSC)
Luiz Colnago (Empresa Brasileira de Pesquisa Agropecuária – Embrapa)
Marco Alvarez (Utah State University)
Vilma Alves de Oliveira (Universidade de São Paulo – USP)

Revisores

Hemerson Pistori (Universidade Católica Dom Bosco – UCDB)
Jacob Scharcanski (Universidade Federal do Rio Grande do Sul – UFRGS)
Joaquim Teixeira de Assis (Universidade Estadual do Rio de Janeiro – UERJ /IPRJ)
José Saito (Universidade Federal de São Carlos – UFSC)
Luiz Colnago (Empresa Brasileira de Pesquisa Agropecuária – Embrapa)
Marco Alvarez (Utah State University)
Vilma Alves de Oliveira (Universidade de São Paulo – USP)

Avaliação das técnicas de filtragem de Kalman e suavização Rauch-Tung-Striebel para a melhoria da qualidade de imagens tomográficas de solos agrícolas

Marcos A. M. Laia Universidade Federal de São Carlos marcoslaia@gmail.com

Abstract

This work presents the space variant noise filtering of tomographic projections based on the Kalman filter. For development and filter selection it were evaluated different modalities of the Kalman filter included the use of artificial neural network. Results were analyzed by means of Improvement in Signal to Noise Ratio (ISNR) measurements, which were obtained in a region of interest (ROI) on the resultant images, reconstructed with the use of a backprojection algorithm. In this context the results qualified the extended Kalman filter with neural network (joint estimation) having three layers (multilayer perceptron) as the best option for filter for soil science tomography.

1. **Introdução**

A qualidade de uma imagem é um dos principais requisitos necessários para sua análise, sendo desejável que o objeto reconstruído esteja bem próximo da amostra que foi ensaiada. O uso de algoritmos desenvolvidos para as áreas de conhecimento humano tem crescido consideravelmente e o processamento de imagens tem melhorado a informação visual para análise e interpretação ou percepção automática por máquinas. Na interpretação humana, temos o uso de imagens de raios-X na área médica, na geologia, nas imagens de satélites, restauração de figuras na arqueologia, na melhoria de imagens físicas, na medicina nuclear, na melhoria de imagens transmitidas por ondas de rádio; enquanto na percepção automática de máquinas temos o reconhecimento automático de caracteres. impressões digitais, computacional, controles de robôs por supervisão, processamento automático de imagens de satélites para reconhecimento de queimadas, de mudanças de clima e de formação de tempestades e furações.

No processamento de imagens, os conceitos buscam: a) o modelamento do funcionamento do olho humano; b) estudo de transformadas de imagens, como a Transformada de Fourier e outras transformadas separáveis de imagens; c) a aplicação filtros que visam recuperar uma imagem e utilização de máscaras para que a imagem processada seja mais aplicável do que a imagem original (real); d) compressão de imagens, para que uma imagem digital seja mais próxima da real com uma redução significativa dos dados; e) segmentação de imagens, para detecção de bordas, de pontos, de linhas e descontinuidade, cujo propósito é divisão da imagem em partes para sua análise; f) reconhecimento e interpretação de imagens, como técnicas de análise baseada em redes neurais, com o propósito de análise e reconhecimento de padrões e de características da imagem [1]. Uma imagem de qualidade permite observar dados que podem ser fundamentais para a aplicação da qual se utiliza o processamento. A qualidade das imagens tomográficas tem extrema importância para a classificação de elementos presentes no solo e análise de porosidade no solo para estudos de técnicas para o aumento da produção agrícola tal como uso na preservação do solo.

Este trabalho tem como objetivo descrever técnicas desenvolvidas para melhorar a qualidade de imagens tomográficas aplicando filtros nos sinais tomográficos antes da reconstrução das imagens.

1.1. Tomografia computadorizada

A aplicação da tomografia computadorizada (TC) na ciência do solo para investigação de propriedades físicas do mesmo é de fundamental importância para o estudo do transporte da água e dos solutos nesse meio. A transmissão direta de raios X ou γ possibilita uma grande contribuição para resolver os diversos problemas da área de solos com resultados obtidos numa escala da ordem de milímetros, enquanto muitas

respostas são esperadas em nível de partículas, macroporos e microporos [2].

Largamente utilizada nas áreas médicas, o uso da TC em ciência do solo foi introduzido por Petrovic [3], Hainswoth e Aylmore [4] e por Crestana [5]. Petrovic demonstrou a possibilidade de usar um tomógrafo computadorizado de raios X para medir a densidade de volumes de solos, enquanto Crestana demonstrou que a TC pode solucionar problemas ligados aos estudos da física da água no solo. A partir desses estudos, originou-se um projeto que envolveu o desenvolvimento de um tomógrafo para a ciência do solo [6].

O uso do computador na tomografia é essencial para a reconstrução da imagem a partir de projeções. Uma abordagem sobre o histórico da tomografia pode ser visto em [7].

A tomografia computadorizada de raios X e γ na escala milimétrica utilizada no domínio da ciência do solo foi introduzida pelo CNPDIA [8], permitindo ver secções transversais do interior de amostras sem que seja necessário cortá-las ou fazer qualquer outro tipo de invasão, utilizando o princípio da atenuação da radiação nos meios materiais. Vários trabalhos foram desenvolvidos para o aprimoramento da visualização das imagens adquiridas e do algoritmo de reconstrução, bem como do hardware desenvolvido [9][10][11][12].

O processo de tomografia envolve a ação de iluminar um objeto em várias direções proporcionais, após armazenagem, extraindo um conjunto de valores que representam amostras de um conjunto de projeções. As projeções podem ser provenientes de diversas fontes como, por exemplo, dos tradicionais raios X, dos raios γ, da ressonância magnética ou do ultra-som. Com base na intensidade emitida pela fonte de raios X e na intensidade captada por um detector na outra extremidade da reta de propagação, pode-se determinar o peso da atenuação devido ao objeto que se faz presente entre fonte e o detector. Este peso da atenuação é um dado crucial para o processo de reconstrução, o qual possibilita deter um mapa de coeficientes de atenuação linear da secção transversal do objeto. Cada dado armazenado é na realidade uma média de alguns parâmetros inerentes do caminho de propagação do raio de iluminação.

O mapa de coeficientes é representado através de pixels cujos valores são dados pelos chamados números CT (nomenclatura decorrente de Computerized Tomography). Esses números são normalizados em função do coeficiente de atenuação da água. Em outras palavras definem-se os números CT por:

Número CT =
$$\frac{\mu - \mu_{H_20}}{\mu_{H_20}}$$
 X 1000 (1)

onde μ é o coeficiente de atenuação do corpo analisado. Com esse número é possível a obtenção de um mapa de coeficientes de atenuação, o que permite uma análise mais detalhada do corpo em estudo. Em medicina convencionou-se que para a água o número CT é igual a 0 (zero).

O raio parte de uma fonte e é detectado por um detector. A função de integração do objeto ao longo do raio é uma integral de linha. Cada integral de linha dos raios paralelos forma uma projeção paralela, a qual pode ser tratada com base na teoria de sinais. Um sinal pode, assim, ser considerado como uma função unidimensional, onde x corresponde às distâncias relativas ao tempo e sua amplitude indica a intensidade no ponto. Então, deve-se assumir um valor no intervalo. Sinais reais são contínuos e podem possuir intensidade também em uma escala contínua. Mas, para haver a possibilidade de análise e tratamento desses sinais, é necessário discretizá-los espacialmente em intensidade. Este processo chama-se digitalização, tendo como consequência um sinal digital. Estudos sobre conceitos como sinal digital, amostragem e vetor de sinal podem ser encontrados em literatura especializadas [13][14]. Nesse processo, pode haver erros nos dados quantificados que, por sua vez. podem provocar falhas que agem diretamente na qualidade das imagens. Esses erros são chamados de ruídos e serão abordados na próxima seção.

1.2. Ruídos em tomografia

A principal fonte de ruído em imagens TC é a variação quântica (quantum mottle), definida como a variação estatística espacial e temporal no número de fótons de raios-X absorvidos no detector. Três processos de interação na radiação com a amostra influenciam na atenuação de feixes de raios-X na TC: o efeito fotoelétrico, o efeito Compton e o efeito de produção de pares. Além das questões relacionadas aos efeitos mencionados que são decorrentes da faixa de energia utilizada na fonte, questões que influenciam a medida tomográfica computadorizada. Dentre elas encontra-se a estatística da contagem de fótons. A probabilidade de detecção de fótons em um intervalo de tempo de exposição t pode ser estimada pela função distribuição de probabilidade de Poisson [15],

$$P_{Poisson} \frac{(\overline{\phi})^n}{\phi! e^n} \tag{2}$$

onde ϕ é o número de fótons e $\bar{\phi}$ é a medida de fotoelétrons emitidos no intervalo de tempo t, conforme a expressão abaixo:

$$\phi = \xi M t \tag{3}$$

onde M é a razão média de fótons (fótons/segundo) e ξ é a eficiência quântica da fotomultiplicadora. A incerteza ou ruído é dada pelo desvio padrão

$$\sigma = \sqrt{\xi M t} = \sqrt{\phi} \tag{4}$$

Logo, a relação sinal-ruído, SNR, apresentada pelo sinal incidente, é:

$$SNR=\frac{\overline{\phi}}{\sigma}=\sqrt{\overline{\phi}} \eqno(5)$$
 Desta relação, avalia-se que, para um número

Desta relação, avalia-se que, para um número pequeno de fótons, o ruído pode ser considerável, porém, com o aumento, o ruído pode vir a ser desprezível. A emissão de elétrons termiônicos no foto-cátodo da multiplicadora causa um aumento nesse ruído. Considerando que o foto-cátodo emite elétrons aleatoriamente em razão da corrente de cátodo incrementado de

$$\sqrt{(\xi M + M)t} \tag{6}$$

tem-se que a nova relação sinal-ruído é dada pela expressão:

$$SNR = \frac{\sqrt{t}\xi M}{\sqrt{\xi M + M}} \tag{7}$$

Na visualização de uma imagem tomográfica, há presença de granulosidade, que é significante para visualização de objetos de baixo contraste. O termo ruído em imagens tomográficas refere-se à variação dos coeficientes de atenuação sobre o valor médio quando uma imagem é obtida de um objeto uniforme [16]. Outros tipos de ruídos presentes nas imagens TC são os erros de arredondamento no programa de reconstrução (ruído do algoritmo), ruído eletrônico e ruído contribuído pelo sistema de visualização. O ruído eletrônico pode ter origem em dispositivos eletrônicos não ideais, tais como resistores e capacitores não puros, terminais de contatos não ideais, corrente de fuga de transistores, efeito Joule, podendo ser também independente do sinal, como interferência externa (elétrica ou até mesmo mecânica) [17][18][19][20].

Os filtros passa-baixa e mediana são soluções para resolver o problema de sinal ou ruído, mas há perda de informações cruciais. Sistemas com diferentes fontes de ruído não apresentam uma solução com o uso desse filtro. Há, portanto, necessidade do uso de filtros mais complexos que podem ser vistos em [21][22][23], que também trazem sua comparação com uma solução do uso de redes neurais (pré-filtragem) com filtro de Kalman discreto.

2. Filtro de Kalman

O processo a ser discutido resolve o problema geral de estimar um estado $x \in \mathcal{R}^n$ de um processo controlado em um tempo discreto que é gerado por uma equação linear de diferenças estocásticas, ou seja:

$$\begin{bmatrix} x_2 \\ \vdots \\ x_k \end{bmatrix} = A \begin{bmatrix} x_1 \\ \vdots \\ x_{k-1} \end{bmatrix} + B \begin{bmatrix} u_1 \\ \vdots \\ u_k \end{bmatrix} + \begin{bmatrix} n_1 \\ \vdots \\ n_{k-1} \end{bmatrix}$$
(8)

com uma medição $z \in \Re^m$ que é

As variáveis aleatórias n_k e v_k representam o ruído do processo e da medida (respectivamente). Assume que elas sejam independentes (entre si) e com a distribuição de probabilidade normal:

$$P(n) \sim N(0, Q) \tag{10}$$

$$P(v) \sim N(0, R) \tag{11}$$

Na prática, as matrizes da covariância do ruído do processo Q e da covariância do ruído da medição R podem mudar com cada passo de tempo ou medida, contudo, aqui se assume que elas são constantes.

A matriz A_{nxn} na equação diferencial (8) relata o estado do tempo anterior do passo (k-1) para o estado atual do passo (k), na ausência de qualquer função direcionada ou ruído do processo. De acordo com Welch e Bishop [24], na prática A_{nxn} pode mudar a cada estado, mas é assume-se como constante. A matriz B_{nx1} relata a entrada opcional do controle $u \in \mathcal{R}^l$ para o estado x. A matriz C_{mxn} é a equação de correção (9) que relata o estado para a medida z_k . Na prática, C_{mxn} pode mudar, mas também é assumido como uma constante.

O objeto de interesse deste trabalho é entender o uso do filtro de Kalman e o uso do algoritmo para separar um ruído de um sinal. Será utilizada uma visão de alto nível e depois será especificada cada equação do algoritmo.

O filtro de Kalman estima um processo utilizando a forma de realimentação (feedback) em um tempo anterior e então obtém realimentação na forma de medidas (ruidosas) no tempo atual. Assim, as equações podem ser divididas em dois momentos: as equações para a atualização do tempo - que são responsáveis pela projeção a frente (no tempo) das estimativas do estado atual e da covariância de erros para obter as estimativas a priori para o passo do próximo tempo - e as equações para a atualização das medidas - que são responsáveis pela realimentação, por exemplo, incorporação de uma nova medida na estimativa a priori para obter uma estimativa a posteriori.

As equações para atualização do tempo podem ser também pensadas como equações preditoras, enquanto as equações para atualização das medidas podem ser tratadas como equações corretoras. Equações de atualização do tempo (preditor) podem ser dadas por:

$$\begin{bmatrix} \hat{x}_2^- \\ \vdots \\ \hat{x}_k^- \end{bmatrix} = A \begin{bmatrix} x_1 \\ \vdots \\ x_{k-1} \end{bmatrix} + B \begin{bmatrix} u_1 \\ \vdots \\ u_k \end{bmatrix}$$
 (10)

$$\begin{bmatrix} P_2^- \\ \vdots \\ P_{r-}^- \end{bmatrix} = A \begin{bmatrix} P_1 \\ \vdots \\ P_{k-1} \end{bmatrix} A^T + Q. \tag{11}$$

Nota-se que estas equações projetam as estimativas do tempo e da covariância através do tempo no passo *k-1* para o passo *k*.

Equações de atualização das medidas (corretor)

$$\begin{bmatrix} K_2 \\ \vdots \\ K_k \end{bmatrix} = \begin{bmatrix} P_1 \\ \vdots \\ P_{k-1} \end{bmatrix} H^T (H \begin{bmatrix} P_2^- \\ \vdots \\ P_k^- \end{bmatrix} H^T + R)^{-1}$$

$$\begin{bmatrix} \hat{x}_2 \\ \vdots \\ \hat{x}_k \end{bmatrix} = \begin{bmatrix} \hat{x}_2^- \\ \vdots \\ \hat{x}_k^- \end{bmatrix} + \begin{bmatrix} K_1 \\ \vdots \\ K_k \end{bmatrix} (\begin{bmatrix} Z_2 \\ \vdots \\ Z_k \end{bmatrix} - H \begin{bmatrix} \hat{x}_2^- \\ \vdots \\ \hat{x}_k^- \end{bmatrix})$$

$$(12)$$

$$\begin{bmatrix} \hat{P}_2 \\ \vdots \\ \hat{P}_k \end{bmatrix} = (1 - \begin{bmatrix} K_1 \\ \vdots \\ K_k \end{bmatrix} H) \begin{bmatrix} P_2^- \\ \vdots \\ P_k^- \end{bmatrix}$$
(14)

A primeira tarefa durante a atualização da medida é computar o ganho de Kalman, Kk. O próximo passo é atualizar para medir o processo para obter z_k , e então gerar um estado estimado a posteriori por incorporação à medida na equação do meio. O passo final é obter uma estimada covariância de erro via a equação 14.

2.1. Filtro de Kalman estendido

Uma solução para sistemas não lineares é o filtro de Kalman estendido (FKE) [23]. Analisando a função de predição do filtro de Kalman, equação 10, é possível observar que o filtro se comporta de forma linear, por ser um sistema linear. Aplicando uma função nãolinear, pode-se obter uma predição ótima para os próximos estados Este algoritmo aplica o filtro de Kalman para sistemas não lineares simplesmente linearizando todos os modelos não-lineares, assim as equações do filtro tradicional podem ser aplicadas. O sistema não linear pode ser reescrito na forma:

$$\begin{bmatrix} x_2 \\ \vdots \\ x_k \end{bmatrix} = F\left(\begin{bmatrix} x_1 \\ \vdots \\ x_{k-1} \end{bmatrix}, \begin{bmatrix} u_1 \\ \vdots \\ u_k \end{bmatrix}, \begin{bmatrix} n_1 \\ \vdots \\ n_{k-1} \end{bmatrix}\right)$$
(17)
$$\begin{bmatrix} z_2 \\ \vdots \\ z_k \end{bmatrix} = H\left(\begin{bmatrix} x_1 \\ \vdots \\ x_{k-1} \end{bmatrix}, \begin{bmatrix} v_1 \\ \vdots \\ v_{k-1} \end{bmatrix}, \begin{bmatrix} v_1 \\ \vdots \\ v_{k-1} \end{bmatrix}\right)$$
(18)

Para a propagação das variâncias, deve-se conhecer as matrizes jacobianas ou hessianas das funções de transição e observação de estado.

Por não se conhecer a função de transferência ou mesmo aumentar a ordem do filtro, procurou-se utilizar um novo método de estimação onde há a possibilidade de estimar novos estados-parâmetros a partir das cadeias ocultas do modelo markoviano.

2.2. Filtro de Kalman estimação conjunta

O principal problema é quando se deve identificar as funções necessárias para estimação dos estados e dos parâmetros. As equações para predição passam a ser descritas como:

$$\mathbf{x}_{\mathbf{k}} = F(\mathbf{x}_{k-1}, \mathbf{w}_k) \tag{19}$$

$$z_k = H(x_k, v_k) \tag{20}$$

A estimação de parâmetros envolve a determinação de um mapeamento não linear

$$y_k = G(x_k, W) (21)$$

onde x_k é a entrada, W é o peso e y_k é a saída e o mapeamento não linear G é parametrizado pelo vetor W. O mapeamento não linear pode ser feito por uma rede neural artificial, onde W é o peso [26]. O aprendizado corresponde à estimação dos parâmetros de W. O treinamento pode ser feito com pares de amostras, consistindo em uma entrada conhecida e saída desejada (x_k, d_k) . O erro de máquinas é definido pela equação 22. O objetivo do aprendizado é minimizar o erro esperado.

$$e_k = d_k - G(x_k, W) \tag{22}$$

Usando um modelo para treinamento da rede como feito neste trabalho, o FKE pode ser usado para estimar os parâmetros escrevendo uma nova representação estado-espacial:

$$w_k = w_{k-1} + v_k (23)$$

$$y_k = G(x_k, w_k) + e_k \tag{24}$$

onde os parâmetros w_k correspondem a um processo estacionário com uma matriz identidade de transição de estado, governado por um ruído processual v_k (a escolha da variância determina a performance da filtragem). A saída y_k corresponde a uma observação não linear em wk. O FKE pode ser aplicado diretamente como uma eficiente técnica de segunda ordem para correção dos parâmetros.

Como o problema em questão consiste em trabalhar sobre uma entrada x_k não observada e requer uma união entre a estimação dos estados e parâmetros, deve-se considerar um problema de estimação dual, considerando uma dinâmica discreto-temporal do sistema não linear:

$$x_{k+1} = F(x_k, v_k, W)$$
 (25)
 $z_k = H(x_k, n_k)$ (26)

$$z_k = H(x_k, n_k) \tag{26}$$

onde ambos os estados dos sistema x_k e o conjunto dos parâmetros W para o sistema dinâmico devem ser estimados somente do sinal ruidoso y_k .

O sistema dinâmico pode ser entendido como uma rede neural, onde W é o conjunto de pesos, e a função F, como uma função de rede neural que utiliza uma entrada x_k . Assim, aplicando essas equações ao FKE, tem-se uma nova função para estimação e para observação. Uma abordagem sobre redes neurais pode ser vista em [25][26][27].

2.3. Algoritmo de suavição Rauch-Tung-Striebel

A solução para o problema de predição linear segue uma maneira direta da teoria básica da propagação da covariância em relação à média da variável. Nesta seção, será considerado o problema da suavização ótima.

Supondo que exista um conjunto de dados sobre o intervalo do tempo $0 < k \le N$. A suavização é uma operação offline que envolve a estimação do estado x_k para $0 < k \le N$, usando todos os dados disponíveis, tanto do passado como do futuro. Assume-se que o tempo final N é fixo para determinar a estimativa do estado ótimo x_k para $0 < k \le N$, e o dado futuro y_i definida por $k < j \le N$. A estimação pertinente ao dado passado é conhecida como a teoria da filtragem adiante. Para estar de acordo com a emissão de uma estimação pertinente para o estado futuro, usa-se uma retro-filtragem, que começa no final do tempo N e executa para trás. Deixando como \hat{x}_k^f e \hat{x}_k^b denotam-se as estimativas dos estados obtidos das recursões para frente e para trás, respectivamente. Dadas estas duas estimativas, o próximo passo a ser considerado é como combiná-los em uma estimativa suavizada total \hat{x}_k , que conta com os dados sobre o intervalo de tempo inteiro. O \hat{x}_k é o símbolo utilizado para a estimativa suavizada e não pode ser confundido com o estimado filtrado (a posteriori).

Escrevendo a equação de processo como uma recursão para o decrescente k, temos

$$x_k = F_{k+1}^{-1} x_{k+1} - F_{k+1,k}^{-1} w_k \tag{27}$$

 $x_k = F_{k+1}^{-1} x_{k+1} - F_{k+1,k}^{-1} w_k$ (27) onde F_{k+1}^{-1} é o inverso para a matriz de transição $F_{k+1,k}$. O raciocínio para a retro filtragem começa no tempo final N, o que é demonstrado na Fig. 1 (a), e a ser contrastada com a filtragem adiante na Fig. 1 (b). Notese que a estimativa a priori \hat{x}_k^b e a estimativa a posteriori \hat{x}_k^b para a retro filtragem ocorrem para a direita e para a esquerda do tempo k, respectivamente, na Fig. 1 (a). Essa situação é o oposto exato do que ocorre no caso da filtragem adiante mostrada na Fig. 1

Para simplificar a apresentação, nós introduzimos as duas definições:

$$S_k = [P_k^b]^{-1}$$

$$S_{\nu}^- = [P_{\nu}^{b^-}]^{-1}$$
(28)

$$S_k^- = [P_k^{D^-}]^{-1} \tag{29}$$

e as duas variáveis intermediárias

$$\hat{z}_{k} = [P_{k}^{b}]^{-1} \hat{\chi}_{k}^{b} = S_{k} \hat{\chi}_{k}^{b} \tag{30}$$

$$\hat{z}_{\nu}^{-} = [P_{\nu}^{b-}]^{-1} \hat{x}_{\nu}^{b-} = S_{\nu}^{-} \hat{x}_{\nu}^{b-}. \tag{31}$$

 $\hat{z}_k = [P_k^b]^{-1} \hat{x}_k^b = S_k \hat{x}_k^b$ (30) $\hat{z}_k^- = [P_k^b]^{-1} \hat{x}_k^b - S_k^- \hat{x}_k^b -$ (31) Então, construindo o raciocínio da figura, tem-se a derivação das seguintes atualizações para o retro filtro:

Atualização da medida:

$$S_k = S_k^- + H_k R_k^{-1} H_k \tag{32}$$

$$z_{\nu} = \hat{z}_{\nu}^{-} + H_{\nu}^{T} R_{\nu}^{-1} v_{\nu} \tag{33}$$

 $S_k = S_k^- + H_k R_k^{-1} H_k$ (32) $z_k = \hat{z}_k^- + H_k^T R_k^{-1} y_k$ (33) onde y_k é o observável definido pela equação de medição, H_k é a matriz de medição e R_k^{-1} é a inversa da matriz de covariância do ruído de medição v_k .

Atualização do tempo:

$$G_k^b = S_{k+1}[S_{k+1} + Q_k^{-1}]^{-1}$$
(34)

$$S_k^- = F_{k+1,k}^T (I - G_k^b) S_{k+1} F_{k+1,k}$$
 (35)

$$\hat{z}_k^- = F_{k+1,k}^T (I - G_k^b) \hat{z}_{k+1} \tag{36}$$

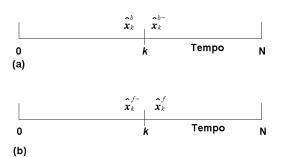


Fig. 1. Ilustrações das atualizações de tempo do suavizador para (a) retro-filtragem e (b) filtragem adiante.

onde G_k^b é o ganho de Kalman para retro-filtragem e Q_k^{-1} é o inverso da matriz de covariância do ruído do processo w_k . O retro-filtro definido pelas equações de medição e atualização do tempo é a formulação de informação do filtro de Kalman. O filtro de informação se distingue do filtro básico de Kalman por propagar a inversa da matriz de covariância de erro melhor do que a matriz de covariância de erro normal.

Sejam os dados observados no intervalo $0 < k \le N$ para o fixo N e suponha-se que se obtêm as duas seguintes estimativas:

 \rightarrow A estimativa *a posteriori* adiante \hat{x}_k^f pela operação do filtro de Kalman nos dados y, para $0 < j \le k$.

 \rightarrow A estimativa *a priori* para trás \hat{x}_k^b pela operação do filtro de informação nos dados y_i para $k < j \le N$.

Com estas duas estimativas e suas respectivas matrizes de covariância de erro conhecidas, o próximo passo de interesse é como determinar a estimativa suavizada de \hat{x}_k e sua matriz de covariância de erro, que incorpora os dados totais sobre o tempo inteiro no intervalo $0 < k \le N$.

Reconhecendo que o ruído do processo w_k e o ruído de medição v_k são independentes, formula-se a matriz de covariância de erro da estimativa a posteriori suavizada \hat{x}_k como se segue:

$$P_k = [[P_k^f]^{-1} + [P_k^{b-}]^{-1}]^{-1}$$
(37)

$$= [[P_k^f]^{-1} + S_k^-]^{-1}$$
(38)

Mais adiante, invoca-se o teorema da inversão de matriz, que pode ser mostrado a seguir. Deixando A e B serem duas matrizes positiva-definidas relacionadas

$$A = B^{-1} + CD^{-1}C^{T}, (39)$$

onde D é outra matriz positiva-definida e C é uma matriz com dimensões compatíveis. O teorema da matriz de inversão demonstra que a inversa da matriz A pode ser expressa como:

$$A^{-1} = B - BC[D + C^TBC]^{-1}C^TB$$
 (40)

Para o problema em que se trabalha, atribuem-se:

$$A = P_k^{-1} \tag{41}$$

$$B = P_k^f \tag{42}$$

$$C = I \tag{43}$$

$$D = [S_k^-]^{-1} (44)$$

onde I é a matriz identidade. Então, aplicando o teorema de inversão de matriz na equação da matriz de covariância de erro, obtém-se:

$$\begin{aligned} P_k &= P_k^f - P_k^f [P_k^{b-} + P_k^f]^{-1} P_k^f \\ &= P_k^f - P_k^f S_k^- [I + P_k^f S_k^-]^{-1} P_k^f. \end{aligned} \tag{45} \\ \text{Desta equação, encontra-se que a matriz de} \end{aligned}$$

$$= P_{\nu}^{f} - P_{\nu}^{f} S_{\nu}^{-} [I + P_{\nu}^{f} S_{\nu}^{-}]^{-1} P_{\nu}^{f}. \tag{46}$$

covariância de erro a posteriori suavizada P_k é menor ou igual do que a matriz de covariância de erro a $posteriori\ P_k^f$ produzida pelo filtro de Kalman, o que é naturalmente devido ao fato de que esta suavização utiliza informação adicional contida nos dados futuros. Este ponto é apresentado na Fig. 2, que descreve as variações de P_k , P_k^f e P_k^{b-} com k para uma situação

$$\hat{x}_k = P_k([P_k^f]^{-1}\hat{x}_k^f + [P_k^{b-}]^{-1}\hat{x}_k^{b-}) \quad (47)$$

 $\hat{x}_k = P_k([P_k^f]^{-1}\hat{x}_k^f + [P_k^{b-}]^{-1}\hat{x}_k^{b-}) \quad (47)$ Usando as equações anteriores para simplificar, obtém-se:

$$\hat{x}_k = \hat{x}_k^f + \left(P_k z_k^- - G_k \hat{x}_k^f \right),$$
 onde o ganho suavizador é definido por

$$G_k = P_k^f S_k^- [I + P_k^f S_k^-]^{-1}, \tag{49}$$

 $G_k = P_k^f S_k^- [I + P_k^f S_k^-]^{-1}, \qquad (49)$ que não pode ser confundido com o ganho de Kalman.

O suavizador ótimo já derivado consiste de três componentes:

- Um filtro adiante na forma de um filtro de Kalman;
- Um retro-filtro na forma de um filtro de informação;
- Um suavizador separado, que combina resultados encorpados nos filtros adiante e retrocesso.

O suavizador Rauch-Tung-Striebel (RTS), contudo, é mais eficiente do que um suavizador de três partes que incorpora o retro-filtro e um suavizador separado em uma entidade simples. Especificamente, a atualização da medição do suavizador RTS é definida

$$P_k = P_k^f - A_k (P_{k+1}^{f-} - P_{k+1}) A_k^T$$
 (50)

onde
$$A_k$$
 é a nova matriz de ganho:

$$A_k = P_k^f F_{k+1,k}^T [P_{k+1}^{f-}] - 1.$$
 (51)

A atualização de tempo correspondente é definida por

$$\hat{x}_k = \hat{x}_k^f + A_k(\hat{x}_{k+1} - \hat{x}_{k+1}^{f-}). \tag{52}$$

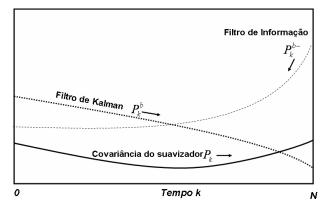


Fig. 2. Ilustração da covariância de erro para a filtragem adiante, retro filtragem e suavizante.

O suavizador RTS procede como a seguir:

- O filtro de Kalman é aplicado para os dados observáveis em uma maneira adiante, que é k = 0,1,2..., de acordo com a teoria básica.
- O suavizador recursivo é aplicado para os dados observados de uma maneira retrocessa, que é k = N - 1, N - 2, ..., de acordo com as equações do RTS.
- As condições iniciais são definidas por:

$$P_N = P_N^F \tag{53}$$

$$\hat{x}_k = \hat{x}_k^f \tag{54}$$

3. Modelagem

Com o conhecimento da função não-linear do processo e um filtro de Kalman que suporte funções lineares, se obtém uma melhora significativa no sinal. Como a transformada de Anscombe está presente na equação do processo, não há filtragem do ruído Poisson, além de o processo poder ser afetado por outros tipos de ruídos.

Uma solução seria utilizar uma rede neural para promover um melhor mapeamento da função de processo, diminuindo o ruído presente nas projeções. Para uma estimação dos pesos da rede neural em conjunto com as estimações dos estados, pode-se utilizar duas modalidades de filtragem: a estimação dual e a estimação em conjunto. Estas modalidades de filtragem determinam que os pesos iniciais sejam conhecidos, onde o próximo estado é obtido em um mapeamento linear com o estado anterior. Assim, temos:

$$x_{k+1} = f(x_k, W_k, v_k)$$
 (55)

Então, utiliza-se um filtro de Kalman para estimar os estados e os pesos. Esta filtragem permite a aplicação em um sistema onde a dinâmica de estado é desconhecida ou caótica (não-determinística).

A Fig. 3 mostra um diagrama de bloco com a implementação do filtro.



Fig. 3. Diagrama de bloco para a filtragem das projeções tomográficas.

Podem-se utilizar as duas modalidades do filtro de Kalman para sistemas não-lineares para compor essa estimação dual. Apesar de ser uma forma mais completa de se estimar, ainda é passível de erros devido ao fato de a estimação do sinal observado ser aproximada.

Uma forma simplificada desse filtro é utilizar a estimação conjunta (uma variação do filtro que combina o filtro de estados aumentados com estimação dual), em que há a possibilidade de estimar, de forma simultânea, os parâmetros necessários para a estimação dos estados do filtro, obtendo em um único filtro a função de estimação e os parâmetros, garantindo uma melhor eficiência no filtro, além de uma implementação simplificada do filtro:

$$\begin{bmatrix}
P_{\theta_i}[n] \\
W
\end{bmatrix} = \begin{bmatrix}
f(P_{\theta_i}[n-1], W, v_k) \\
I * W
\end{cases}$$

$$P_{\theta_i}[n] = h(P_{\theta_i}[n], n_k) \tag{56}$$

onde W são os pesos para a função f que pode ser descrita como uma rede neural e I uma matriz identidade.

Um corpo de prova ou phantom é um objeto confeccionado especialmente para caracterização e calibração do tomógrafo ou outros experimentos. Assim, para a caracterização dos resultados da pesquisa, um phantom homogêneo cilíndrico foi construído com um material composto de Nylon (Fig. 4).

O phantom heterogêneo foi construído com uma base de plexiglass em forma cilíndrica, com apenas quatro comprimentos cilíndricos para inserção de materiais.

Os *phantoms* têm 60 mm de diâmetro, sendo que as amostras de cálcio e água possuem 19 mm de diâmetro e as amostras de fósforo e alumínio, 22 mm de diâmetro, como ilustrado na Fig. 5. As tomografias destes corpos de prova foram imageadas utilizando o minitomógrafo de primeira geração.

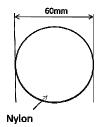


Fig. 4. Diagrama para construção do phantom homogêneo.

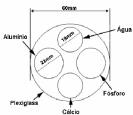


Fig. 5. Diagrama para construção do phantom heterogêneo.

4. Resultados obtidos

Os resultados obtidos com a aplicação do filtro para os *phantoms* podem ser vistos nas Fig. 6 e Fig. 7. Utilizou-se neste trabalho uma rede neural do tipo perceptron multicamadas com duas camadas, sendo a camada de entrada com 1 neurônio, 10 neurônios na camada oculta com a função de transferência ou ativação sigmoidal e um neurônio na camada de saída com a função de transferência linear.

Na Fig. 6 foram utilizados os *phantoms* de baixa resolução (sinal de baixa amostragem). Em (a) e (b), temos os *phantoms* originais, ou seja, sem a filtragem dos sinais tomográficos antes da sua reconstrução, com uma amostra homogênea e outra heterogênea.

Em seguida, utilizou-se o filtro de Kalman discreto com as variâncias Q e R com valores de 0,5 e 1, em (c) e (d). Em (c) é possível perceber uma melhoria devido ao fato de a distribuição dos valores dos pixels ser mais uniforme. Em (d), além da melhoria, é perceptível um pouco de distorção na parte inferior das amostras.

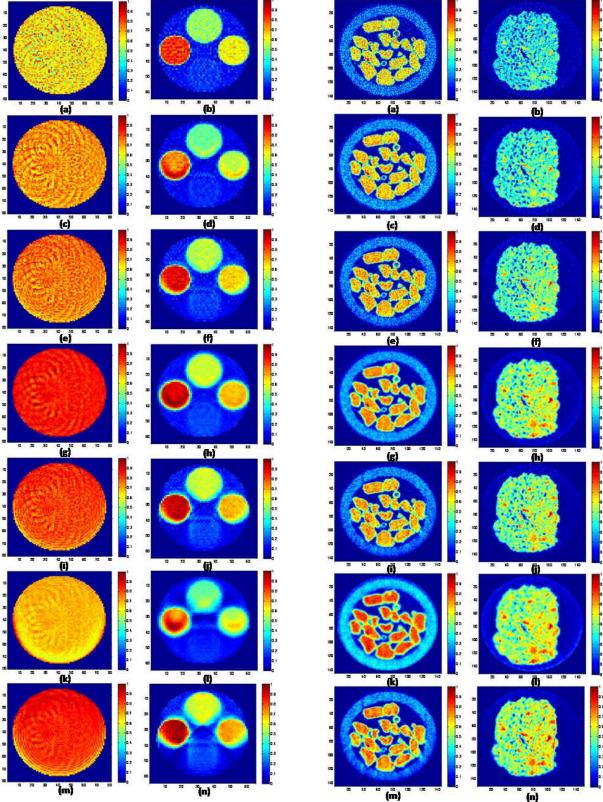


Fig. 6. *Phantoms* utilizados para a calibração do tomógrafo.

Fig. 7. Phantoms com amostras reais de solo.

Essa distorção é devida à natureza do filtro de ter uma filtragem on-line, conforme a filtragem do sinal que tende a um valor ótimo do ganho de Kalman. O uso da rede neural no filtro de Kalman permitiu que apenas o ruído do sistema fosse filtrado, ou seja, o ruído branco.

Esta modalidade do filtro permite uma melhor convergência, ou seja, os valores tendem a chegar numa solução ótima de forma mais rápida do que na modalidade padrão. A pequena distorção encontrada no fundo da imagem (e) e em cada amostra (f) é função do uso de vários neurônios na camada oculta, assim, há uma perda de qualidade no início da filtragem de cada sinal.

O algoritmo de suavização RTS após aplicação do filtro na modalidade discreta permite que, no final da filtragem, os valores ótimos sejam reaplicados ao longo do sinal a partir do final até o início. Na imagem (g) e, principalmente, na imagem (h), é possível uma melhor distribuição das imagens sem distorção, pois os sinais foram filtrados de forma igual. No caso da aplicação do algoritmo com o filtro de Kalman com redes neurais, houve uma uniformização, mas com pouca melhoria em relação ao algoritmo em sua forma pura, como se pode observar nas imagens (i) e (j).

Como segundo experimento, resolveu-se aumentar os valores das variáveis Q e R para 0,1 e 2, respectivamente, e aplicar os filtros em conjunto com o suavizador RTS. O objetivo é a diminuir a incerteza do ruído do processo e aumentar a incerteza do ruído de observação, com o objetivo de produzir uma melhor filtragem. Como o algoritmo de Kalman discreto acaba filtrando o ruído Poisson, é perceptível uma pequena distorção do sinal nas amostras heterogêneas (k) e uma menor variância na imagem homogênea (1). Já as imagens resultantes com o filtro de Kalman com redes neurais ainda apresentaram pequenas distorções (m) e (n), mas sem um aumento ou presença de artefatos. Para o uso em aplicações reais, utilizaram-se *phantoms* obtidos a partir de tomografias de solo como areia e um torrão de terra. Essas imagens servem para fazer um comparativo com o sistema real. Também foram aplicadas as mesmas variâncias Q e R (0,5 e 1) nestes phantoms.

Nas imagens da Fig. 7, é possível perceber que as amostras possuem uma qualidade maior do que as anteriores, com pequenos detalhes visíveis, o que ocorre por terem uma amostragem maior. O objetivo é manter esses detalhes e amenizar o ruído nessas imagens.

Nas imagens (a) e (b), se encontram as duas amostras originais, de areia e o torrão, respectivamente. A imagem (a) consiste em vários grãos de areia em um tubo enquanto a imagem (b), de um torrão para análise de porosidade.

Em (c) e (d) foi aplicado o filtro de Kalman discreto e percebe-se uma melhoria na qualidade da imagem de ambas as amostras em relação a imagem original, mas também uma perda de detalhamento na imagem do borrão, pois o filtro não consegue definir o que é ruído ou parte da amostra, já que o sinal tende a ser caótico e, apenas trabalhando com o valor anterior do sinal, não permite uma abordagem como um todo.

Em (e) e (f) foi aplicado o filtro de Kalman com redes neurais. Os resultados foram pouco melhores do que o filtro anterior, havendo uma melhor filtragem e mantendo detalhes.

Em (g) e (h), foram aplicados o filtro de Kalman discreto e o suavizador RTS. Os grãos de areia estão com uma variância menor no interior, mas na imagem do torrão alguns detalhes foram perdidos.

Nas imagens (i) e (j) foram aplicados o filtro de Kalman com redes neurais e o suavizador RTS. É possível perceber que o apenas o ruído gaussiano da equação de observação (do detector) foi novamente filtrado, o que permitiu ainda manter detalhes dos valores dos poros (por serem altos) na imagem do torrão e presença de ruído nos grãos de areia.

Como nos *phantoms* de calibração, foram utilizados novos valores nas variâncias de Q (0,1) e R (2) e o uso do suavizador RTS para gerar novas amostras filtradas. Em (k), com o uso do filtro de Kalman discreto, todos os tipos de sinais são filtrados, tratados como uma distribuíção gaussiana, pois o valor da incerteza da observação e a confiança na estimação do sinal foram ampliados e apresentaram a melhor imagem do experimento, mantendo os pequenos detalhes. Em (l) houve uma diminuição dos números de poros junto com os ruídos. Em (m) é possível perceber a presença do ruído Poisson e em (n) a presença da grande maioria dos poros do torrão. Estes últimos filtros utilizaram o filtro de Kalman com redes neurais.

5. Conclusões

A pré-filtragem dos sinais tomográficos é uma técnica que permite a filtragem dos sinais tomográficos antes de sua reconstrução.

O uso do filtro de Kalman discreto permitiu que os sinais fossem pré-filtrados, apresentando uma redução considerável de ruídos. Em sinais tomográficos cujos sinais não se apresentam de maneira não uniforme, o resultado não foi tão preciso, pois apenas a informação do momento anterior não era capaz de processar uma estimativa mais próxima ao valor ideal. A filtragem também apresenta um aspecto importante quanto à filtragem de ruídos Poisson. O filtro tende a tratar o ruído do emissor de fótons do tomógrafo como se fosse do receptor, assim tratando como um ruído branco.

Esse tipo de filtragem nem sempre pode ser a melhor escolha por essa restrição do filtro de não poder tratar o ruído com uma distribuição de Poisson.

O uso do filtro de Kalman estendido com redes neurais permite uma memorização do comportamento anterior do sinal e avalia através desse procedimento qual a melhor estimação dos estados. É um algoritmo que apresenta uma complexidade maior do que o filtro de Kalman discreto por envolver cálculo de jacobianas para linearização da rede neural e estimação de parâmetros, fazendo com que o uso do algoritmo seja limitado pela demanda de memória e processamento.

O uso do algoritmo de suavização apresentou melhorias significativas nos filtros pela otimização das antigas amostras após a filtragem. A combinação das duas técnicas permitiu obter imagens de qualidade após a reconstrução dos sinais.

O aumento da confiabilidade no processo e o aumento da incerteza na observação permitiram que houvesse uma melhor filtragem nas projeções do experimento nas projeções, mas esse aumento e uma distância maior entre esses valores podem fazer com que haja distorções (erros na estimação do próximo valor) e suavização dos sinais, levando a perda de detalhes.

Referências

- [1] Laboratório de Robótica da Universidade de São Paulo, http://robot.lac.usp.br, acessado em 27/04/2004.
- [2] S. Crestana, "Técnicas recentes de determinação de características do solo." In: Reunião Brasileira de Manejo e Conservação do Solo e da Água, 10, 1994, Resumos... Florianópolis: Sociedade Brasileira de Ciência do Solo, p86-97, 1994.
- [3] A. M. Petrovic, J.E. Siebert, P.E. Rieke, "Soil bulk analysis inthree-dimensions by computed tomographic scanning", Soil Sci. Soc. Am. J., n.46, p.445-450, 1982.
- [4] J. M. Hainsworth, L. A. G. Aylmore, "The use of the computed-assisted tomography to determine spatial distribution of soil water content", Aust. Journal Soil Res. N. 21, p.1435-1443,1983.
- [5] S. Crestana, "A Tomografia Computadorizada com um novo método para estudos da física da água no solo", São Carlos, USP, Tese de Doutorado, 140 páginas, 1985.
- [6] P. E. Cruvinel, "Minitomógrafo de raios X e raios-gama computadorizado para aplicações multidisciplinares". Campinas, UNICAMP. Tese de Doutorado, 329p, 1987.
- [7] M. A. M. Laia, "Filtragem de projeções tomográficas do solo utilizando Kalman e Redes Neurais", São Carlos, UFSCAR, Tese de mestrado, 2007.
- [8] P. E. Cruvinel et al, "X and γ-ray computerized minitomograph scanner for soil science", IEEE Transactions on Instrumentation and Measurement, V.39, N.5, p.745-750, october, 1990.

- [9] Y. R. Venturini, "Análise quantitativa da qualidade de imagens digitais com o uso de espectro de Wiener". São Carlos, UFSCar, Tese de Mestrado, 89 páginas, 1995.
- [10] E. R. Minatel, "Desenvolvimento de Algoritmo para Reconstrução e Visualização Tridimensional de Imagens Tomográficas com uso de Técnicas Frequenciais e Wavelets", São Carlos, UFSCar, Tese de Mestrado, 148 páginas, 1997.
- [11] L. F. Granato, "Algoritmo adaptativo para a melhoria em imagens tomográficas obtidas em múltiplas energias", São Carlos, UFSCar, Tese de mestrado, 135 páginas, 1998.
- [12] N. D. A. Mascarenhas, C. A. N. Santos, P. E. Cruvinel, "Transmission Tomography under poisson noise using the Anscombe Transformation and Wiener Filtering of the projections". Nuclear Instruments And Methods In Physics Research Section A, Estados Unidos, v. 423, p. 265-271, 1999.
- [13] E. O. Brigham, "The Fast Fourier Transform and Its Applications", Prentice Hall, New Jersey, 1998.
- [14] E. Deremack, D.G. Crowe, "Optical Radiation Detectors", -John Wiley & Sons, Inc, 300p, 1984.
- [15] W. R. Hender, "The physical principals of computed tomography", EUA, 1983.
- [16] A. D. Ziel, "Noise in measurements"- John Wiley & sons, inc.; 288p, 1976.
- [17] A. J. Duerinckx, A. Macocski, "Polycromatic Streak Artifacts in Computed Tomography Images", J. Comput. Assist. Tomogr., 2.481, 1978.
- [18] P. M. Joseph, R.D. Spital, "A method for correction bone-induced artifacts of CT scanners", 1978.
- [19] G. S. Ibbott, "Radiation therapy treatment planning and the distortion of CT images", Med. Phys, 7:261,1980.
- [20] L. F. Granato, "Algoritmo adaptativo para a melhoria em imagens tomográficas obtidas em múltiplas energias", São Carlos, UFSCar, Tese de mestrado, 135 páginas, 1998.
- [21] M. A. M. Laia, P. E. Cruvinel, "Filtragem de projeções tomográficas utilizando Kalman Discreto e Rede Neurais", IEEE América Latina,vol. 6, ed. 1, março, 2008.
- [22] M. A. M. Laia, P. E. Cruvinel, A. L. M. Levada, "Filtragem de projeções tomográficas da ciência do solo utilizando transformada de Anscombe e Kalman", DINCON'07, São José do Rio Preto, 2007.
- [23] M. A. M. Laia, P. E. Cruvinel. "Filtragem de projeções tomográficas do solo utilizando Kalman e Redes Neurais numa estimação conjunta", DINCON'08, Presidente Prudente, 2008.
- [24] G. Welch, G. Bishop, "An introduction to the Kalman Filter". Departament of Computer Science, University of North Carolina at Chapel Hill. 2004
- [25] P. Trealeaven, M. Pacheco, M. Vellasco, "VLSI Architectures for Neural Networks", *IEEE MICRO*, pp. 08-27, December, 1988.
- [26] E. B. Pizzolato, "Implementação de Redes Neurais no CPER", São Carlos, UFSCar, Dissertação de mestrado, 95 páginas, 1992.
- [27] W. S. McCulloch, W. Pitts, "How we know universals: the perception of auditory and visual forms", *Bulletin of mathematical Biophysics*, vol.9, pp.127-147, 1947.

Modelo de Visualização 2D e 3D de Imagens Tomográficas de Raios X de Amostras Agrícolas, Baseado em Técnicas de Processamento Paralelo e Realidade Virtual

Maurício Fernando Lima Pereira Embrapa Instrumentação Agropecuária Rua XV de Novembro, 1452 São Carlos, SP - Brasil mauricio@cnpdia.embrapa.br

Leonardo Castro Botega

Departamento de Computação - Universidade Federal de São Carlos
Rod. Washington Luís, km 235 São Carlos - SP - Brasil
leonardo_botega@dc.ufscar.br

Resumo

Neste trabalho é apresentado um modelo para reconstrução e visualização bidimensional(2D) e tridimensional(3D) de imagens tomográficas de raios X, para aplicação na área de físicas de solos. O modelo engloba a filtragem de projeções a priori para eliminação de ruídos, a paralelização dos algoritmos de reconstrução tomográfica 2D e 3D, sendo esta baseada em inserção de planos virtuais através de um algoritmo de interpolação por B-Spline-Wavelets. Completando o modelo, foram desenvolvidos um ambiente para visualização de cortes e extração de atributos de densidade e coeficiente de atenuação linear e dois ambientes de visualização 3D baseados em biblioteca Visualization Toolkit (VTK) e em técnicas da Realidade Virtual (RV). Os resultados mostraram que houve uma redução do tempo de reconstrução das imagens das amostras e que estes ambientes auxiliam os usuários na análise de amostras de solo, permitindo a extração de medidas de forma interativa e não invasiva.

1. Introdução

Avaliando a evolução que vem ocorrendo na área de física de solos, percebe-se o crescente interesse da comunidade científica para o desenvolvimento e aplicação de técnicas não invasivas para o estudo de características do solo. Dentre as técnicas utilizadas, destaca-se a tomografia computadorizada (TC) de raios X, que se sobressai em relação às demais técnicas aplicadas na física de solos, como a gravimétrica e a sonda de nêutrons [21] [4], devido à sua preci-

são na extração de atributos físicos, como densidade e umidade, e pela característica de possibilitar o exame de amostras de solo de forma não destrutiva [1] [3] [16]. Outra vantagem oferecida pela tomografia computadorizada, em relação às demais, é a possibilidade de fazer-se uso, após a reconstrução, das ferramentas do processamento de imagens para auxiliar a investigação dos fenômenos físicos que ocorrem solo.

Além dos desenvolvimentos ocorridos na área de ciência do solo na aplicação da tomografia, a pesquisa de madeiras recentemente também tem utilizado técnicas da TC para determinar a medida da densidade de madeira, a qual é um importante parâmetro, dado que ela é relacionada à propriedades físicas e anatômicas da madeira e muitas vezes correlacionada a sua qualidade [11].

Este trabalho apresenta um modelo de reconstrução tridimensional e visualização de amostras agrícolas que se baseia em técnicas do processamento paralelo e filtragem preditiva para eliminação de ruído das projeções. O foco do trabalho está na modelagem, implementação e validação do modelo de reconstrução; na capacidade de acelerar o processo tomográfico com uso de arquiteturas paralelas de processamento para permitir sua aplicação em grande escala e no desenvolvimento de ambientes de visualização e análise interativos. Os resultados encontram aplicação em estudos sobre:

- Solos e plantas (estruturas de formação de poros e texturas):
- Movimentação de água e soluto nos solos;
- Distribuição de raízes.

2. Materiais e métodos

A Figura 1 apresenta os módulos que compõem o modelo de reconstrução e visualização tridimensional desenvolvido neste trabalho. O modelo determina que os dados de projeções obtidos pelos tomógrafos agrícolas sejam filtrados e reconstruídos, através dos módulos paralelos de filtragem e reconstrução tomográfica bidimensional, gerando imagens bidimensionais dos cortes tomografados. Através de um algoritmo de reconstrução tridimensional por interpolação B-Spline-Wavelets, que utiliza sobreposição de fatias, é realizado o preenchimento do espaço existente entre os planos de forma a aumentar a resolução do objeto 3D, preservando-se as características de textura do solo. Após a reconstrução 3D, os objetos podem ser analisados em interfaces de visualização 2D ou pode-se interagir através de uma interface de análise dos objetos 3D, desenvolvida em C++ e VTK ou com uso de RV.

A RV nasceu nos anos 80 sob a necessidade de diferenciar simulações computacionais tradicionais dos mundos sintéticos que começavam a despontar. Esta iniciativa foi creditada a pesquisadores como Bolt [2] e Lanier [10].

Acadêmicos, desenvolvedores de software e pesquisadores buscam definir a RV baseados em suas próprias experiências, tornando-a largamente difundida. Tecnicamente, o termo relata uma experiência imersiva e interativa baseada em imagens geradas por computadores, renderizadas ou não em tempo real [18].

Machover afirma que a qualidade de um sistema de RV é essencial, porque estimula ao máximo o usuário, de forma criativa e produtiva, provendo *feedbacks* de forma coerente aos movimentos dos usuários [12].

Sob a perspectiva tecnológica, o objetivo principal da RV é fazer o participante sentir sua presença no mundo virtual [6]. Para criar esta sensação, sistemas de RV integram sofisticados dispositivos tais como luvas digitais, vídeo-capacetes, cavernas digitais, mesas digitais e outros.

Até o presente momento, apenas algumas unidades de pesquisa têm desenvolvido projetos com aplicações de RV na área de visualização científica, como a reconstrução tomográfica, devido ao alto custo e à dificuldades técnicas. Entretanto, algumas propostas têm surgido para minimizar as dificuldades de desenvolvimento, manutenção dos sistemas e programas necessários. Assim, recursos humanos qualificados, envolvendo a integração entre diferentes áreas do conhecimento, têm sido preparados para a otimização e democratização da utilização das tecnologias envolvidas [15].

2.1. Reconstrução tomográfica bidimensional

O algoritmo paralelo de reconstrução tomográfica baseia-se no algoritmo de retroprojeção filtrada, o qual

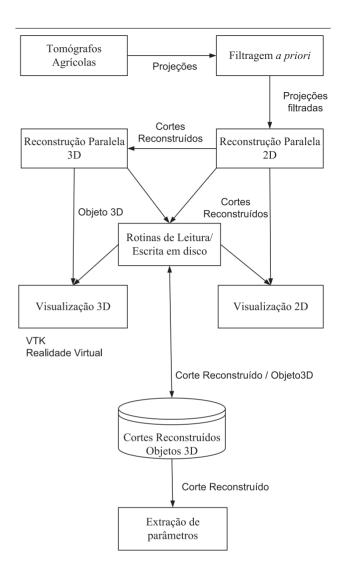


Figura 1. Modelo de reconstrução 3D e de visualização desenvolvido neste trabalho

está fundamentado na transformada de Radon [7].

A reconstrução por retroprojeção filtrada pode ser separada em duas equações. A primeira, responsável pela filtragem dos dados das projeções obtidas em cada ângulo θ , dada por :

$$Q_{\theta}(t) = \int_{-\infty}^{\infty} S_{\theta}(\omega) |\omega| e^{j\omega t} d\omega$$
 (1)

onde $S_{\theta}(\omega)$ representa a transformada de Fourier convoluída com o filtro rampa no domínio da freqüência. Depois de filtradas, as projeções são retroprojetadas para se obter uma função do objeto. A segunda (Eq. 2) apresenta a equa-

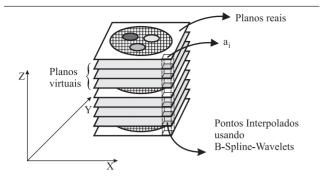


Figura 2. Diagrama ilustrando a inserção de planos virtuais entre planos reais na reconstrução tridimensional

ção de retroprojeção das projeções filtradas.

$$g(x,y) = \int_{0}^{2\pi} Q_{\theta}(x\cos(\theta) + y\sin(\theta))d\theta \qquad (2)$$

onde cada componente representa um pixel de coordenadas (x,y) na imagem reconstruída g(x,y). Na forma discreta, a retroprojeção filtrada é presentada por:

$$\hat{\bar{g}}(x,y) = \frac{\pi}{K} \sum_{i=1}^{K} Q_{\theta} \left(x \cos \left(\theta_i \right) + y \sin \left(\theta_i \right) \right)$$
 (3)

onde K ângulos θ são os valores discretos de θ para cada $P_{\theta}(t)$ conhecido.

Neste trabalho são utilizadas projeções obtidas de amostras de solo que foram coletadas pelos tomógrafos dedicados sob energia de 58 KeV, passo angular de 1°, passo linear 0.083 mm e tempo de aquisição de 4 segundos por amostra de projeção.

2.2. Reconstrução tridimensional

Uma função de aproximação Spline f de ordem m e passo μ é usada como função de aproximação e é dada pela Eq. (4) [23][14] :

$$f(\mu) = \sum_{i=-2}^{N+2} a_i \beta(N\mu - i) \tag{4}$$

onde N e a_i representam, respectivamente, o número de pontos conhecidos e os pontos reais extraídos dos planos reais reconstruídos, tal qual mostra a Figura 2. Nesta implementação, são utilizados dois pontos fantasmas antes do ponto inicial e dois pontos após o último ponto para garantir que a função B-Wavelet irá passar no primeiro e no último ponto [13].

De modo a otimizar o cálculo , a função $\beta(x)$, também chamada de função de *blending*, foi implementada neste trabalho como

$$\beta_m(x) = \begin{cases} \frac{\frac{1}{6}(2+x)^3}{\frac{1}{6}(4-6x^2-2x^3)} & -2 < x \le -1\\ \frac{\frac{1}{6}(4-6x^2-2x^3)}{\frac{1}{6}(4-6x^2+2x^3)} & 0 < x \le 1\\ \frac{\frac{1}{6}(2-x)^3}{\frac{1}{6}(2-x)} & 1 < x < 2\\ 0 & 2 \le |x| \end{cases}$$
(5)

Para obter a função de interpolação, uma função de aproximação dada pela Eq. (6) foi utilizada.

$$f(\mu) = \sum_{i=-2}^{N+2} A_i \beta_m (N\mu - i)$$
 (6)

onde A_i , denominados pontos de controle, substituem a_i . Esses pontos de controle são obtidos através da multiplicação $A=M^{-1}a$, onde M é dado por

$$M = \begin{bmatrix} \frac{N}{2} & -\frac{N}{2} & 0 & 0 & \dots & 0 & 0\\ \frac{1}{6} & \frac{2}{3} & \frac{1}{6} & 0 & \dots & 0 & 0\\ 0 & \frac{1}{6} & \frac{2}{3} & \frac{1}{6} & \dots & 0 & 0\\ 0 & \dots & \dots & \dots & \dots & 0 & 0\\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots\\ 0 & 0 & \dots & \frac{1}{6} & \frac{2}{3} & \frac{1}{6} & 0\\ 0 & 0 & \dots & 0 & \frac{1}{6} & \frac{2}{3} & \frac{1}{6}\\ 0 & 0 & \dots & 0 & 0 & -\frac{N}{2} & \frac{N}{2} \end{bmatrix}$$
 (7)

2.3. Modelagem de sistemas paralelos

A maioria dos problemas computacionais possui um conjunto variado de soluções que podem, no caso do desenvolvimento de um algoritmo paralelo, ser bastante diferentes das soluções seqüenciais. Com isso, é importante levar em conta que paradigmas para sistema paralelos auxiliam na escolha de uma melhor forma de modelagem de problemas do mundo real em um conjunto de pequenos pedaços que reunidos atendem às necessidades impostas pelos problemas. A metodologia PCAM (*Partitioning, Communication, Agglomeration, Mapping*) [5], utilizada neste trabalho, mostra um paradigma de desenvolvimento de algoritmo paralelo baseado em quatro etapas:

- 1. Particionamento;
- 2. Comunicação;
- 3. Aglomeração;
- 4. Mapeamento.

A Figura 3 ilustra conceitos contidos em cada etapa. Basicamente, a metodologia consiste em dividir o problema em um conjunto de pequenas tarefas. Uma vez que isto tenha sido realizado, inicia-se a fase de comunicação, onde se

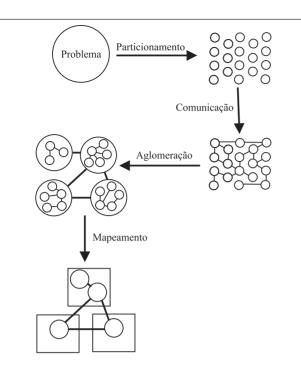


Figura 3. Modelo PCAM com as quatro fases para modelagem de um sistema paralelo

organiza a forma como estas tarefas irão trocar dados entre si. A fase de aglomeração consiste em agrupar as tarefas que tenham intensa comunicação em tarefas maiores e, finalmente, já com vistas ao tipo de máquina paralela que será utilizada. No mapeamento distribuem-se as tarefas entre os processadores disponíveis na máquina paralela.

2.4. Realidade Virtual

Neste modelo, a utilização de um ambiente de RV sobre o algoritmo de reconstrução é baseada em uma interface principal, desenvolvida como um controle principal, provendo acesso intuitivo para os usuários. Esta interface, através de frames independentes, é capaz de acessar tanto uma visualização completa da amostra reconstruída, quanto os diversos níveis de cinza que compõem suas partes, provendo uma análise individual das mesmas, através de operações de threshold. Todos os recursos utilizados na implementação das técnicas de RV foram desenvolvidos utilizando a linguagem de programação Java e a API Java3D, a qual é baseada em estrutura hierárquica denominada Grafo de Cena, o qual se divide em subgrafo de visualização e subgrafo de conteúdo [20].

Para que as atividades desta fase possam ser iniciadas, torna-se necessária a utilização de métodos do pacote do VTK, descritos anteriormente, as quais são capazes de converter os arquivos que possuem as representações dos ob-

jetos tridimensionais, em formatos praticáveis em ambiente Java3D, possibilitando a implementação da classe importadora. Desta maneira, o objeto reconstruído tridimensionalmente e salvo no formato (.vtk) [9], é escrito sob o formato *Wavefront File Format* (.obj) [24].

Posteriormente, com os arquivos já preparados, uma nova classe será implementada, derivada da classe *Object-File*, a qual provê subsídios para trazer todas as características do modelo ao ambiente Java, utilizando-se de métodos pré-implementados, portáveis para a reutilização. Esta nova classe será capaz de importar o modelo completo, reconstruído e exportado sob o formato Wavefront, para o ambiente virtual, mantendo todas as suas características originais, tais como aparência (*Appearance*), material (*Material*) e geometria (*Geometry*).

Transformações físicas lineares foram escolhidas para serem inicialmente conectadas ao sistema, tais como rotação, translação, escala, reflexão e cisalhamento, definidas através de entradas por teclado e disponíveis para cada conjunto de dados do modelo.

No ambiente de visualização por RV, objetos Behavior foram instanciados para interpretar as ações dos usuários por eventos de entrada e traduzi-los em transformações de translação e rotação, disponíveis também para todos os modelos. Assim, a classe Behavior faz a conexão entre as interações e as reações, provendo mudanças no subgrafo de conteúdo.

Outro recurso acoplado ao sistema é a obtenção de informações dos voxels das amostras, que provê para os usuários informações a respeito de um ponto específico, através de seleção por mouse (picking). Os dados disponíveis para picking estão divididos em dois aspectos: aspectos de cena e tomográficos. Considerando o aspecto de cena, usuários podem obter informações como as fronteiras do modelo reconstruído, o número de subgrafos da cena, o modo de composição das geometrias da cena, a distância entre o modelo e o observador, as coordenadas do modelo e as coordenadas do vértice mais próximo. Sob o aspecto tomográfico, as informações disponíveis são os atributos de cor do modelo (RGBA e HSL), os atributos de material ou reflexão, o grau de transparência, o modo de renderização da geometria, tons de cinza do voxel e o coeficiente de atenuação linear de um ponto específico.

A manipulação e a obtenção de informações dos modelos também podem ser atingidas através da utilização de uma P5Glove [19]. Este dispositivo não convencional de entrada de dados tem seis graus de liberdade, permitindo que os usuários transladem e rotacionem tanto a cena virtual, como os modelos que nela se encontram, selecionando as representações desejadas de forma intuitiva e movendo-as por toda a cena sintética. Para este propósito, uma API e um driver específico foram adotados, responsáveis por fornecer subsídios para o comportamento da luva como um todo [8]. Comparado ao software do fabricante, o novo driver oferece filtragem de dados, maior precisão e melhor acesso às informações dos sensores.

Posteriormente, um sistema de luzes dinâmicas foi inserido em todo o contexto tridimensional, deixando o usuário escolher dentre quatro tipos de fontes de iluminação, tais como Ambiente, Direcional, Pontual e Pontual Angular. Cada fonte detém uma série de parâmetros, com influência direta sobre a direção, posição, atenuação, ângulos e cores das luzes envolvidas. Seus efeitos podem ser vistos sobre todos os modelos de dados, contribuindo para o realismo da cena.

Adicionalmente, a visualização por RV ainda permite que o usuário escolha a forma de renderização dos polígonos. Dentre as formas disponíveis estão: Faces, Arestas e Nuvem de Pontos.

Visando uma maior interatividade, uma das principais diretivas de sistemas de RV, um sistema de cores em tempo real foi implementado. Através deste recurso, tanto um modelo completo quanto suas partes formadoras podem ser dinamicamente coloridos. As novas cores dos modelos são escolhidas através de uma paleta de cores bidimensional.

3. Resultados

3.1. Paralelização dos algoritmos de reconstrução 2D e 3D

O modelo desenvolvido implementa dois módulos para reconstrução 2D e 3D, que através de uma implementação paralela consegue explorar, de forma otimizada, as características das arquiteturas paralelas, acelerando o processo de reconstrução. Estes módulos podem ser utilizados em *clusters*, arquiteturas paralelas baseadas em processadores DSP ou em computadores baseados em processadores de múltiplos núcleos.

A organização dos algoritmos paralelos de reconstrução 2D é apresentada na Figura 4. No algoritmo paralelo de reconstrução 2D, a matriz de projeções, obtida durante o processo de varredura, é dividida igualmente entre os processos trabalhadores, os quais são responsáveis por realizar a filtragem e a retroprojeção dos pontos. Ao final do processo, os pontos retroprojetados por cada trabalhador são enviados ao processo gerente que é responsável por organizá-los em uma imagem reconstruída final.

A Figura 5(a), (b) e (c) apresenta o resultado da reconstrução tomográfica bidimensional paralela de amostras de solos, as quais foram utilizadas como cortes reais na reconstrução tridimensional paralela.

No algoritmo de reconstrução 3D paralelo, apresentado na Figura 6, o objeto 3D é dividido em blocos com planos reais, os quais são enviados a cada processo trabalhador, que fica responsável por inserir planos virtuais entre os pla-

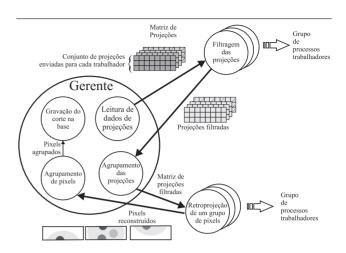


Figura 4. Tarefas da reconstrução paralela 2D

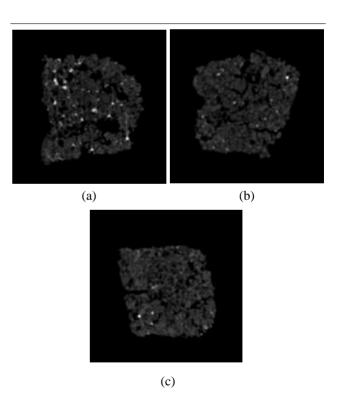


Figura 5. Imagens de solo reconstruídas pela algoritmo paralelo (a,b e c)

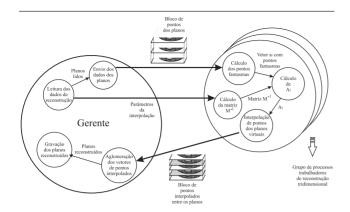


Figura 6. Tarefas da reconstrução paralela 2D

nos reais do seu bloco. A utilização do método de interpolação por B-Spline-Wavelets assegura, devido ao uso de informações de vizinhança, uma representação mais real das características de textura e acurácia dos coeficientes de atenuação, nos planos virtuais gerados. Quando cada processo trabalhador termina sua tarefa, todos os blocos são organizadas pelo processo gerente em um objeto 3D único.

3.2. Avaliação da correlação entre coeficiente de atenuação linear e tons de cinza do algoritmo paralelo de reconstrucão 2D

Para avaliar a precisão do algoritmo paralelo de reconstrução 2D, buscou-se estabelecer a correlação existente entre as variáveis, o coeficiente de atenuação e os tons de cinza da imagem reconstruída. O coeficiente de correlação mede a relação existente entre as variáveis. Se o seu resultado estiver próximo de +1 ou de -1, isto indica que os dados se ajustam bem à reta estimada [22].

Na avaliação, utilizou-se um *phantom*¹ heterogêneo de *Plexiglass*², com 6 cm de diâmetro, que contém os elementos cálcio, fósforo, alumínio e água, como ilustra a Figura 7.

Para o processo de tomografia, usaram-se os seguintes parâmetros:

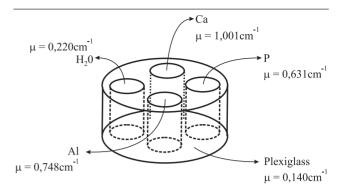


Figura 7. *Phantom* de calibração com os elementos Cálcio (Ca), Alumínio (Al), Fósforo (P), Água (H_20) e *Plexiglass*

 $\begin{array}{lll} \mbox{Translação total}: & 6\mbox{ cm} \\ \mbox{Passo linear}: & 0,100\mbox{ cm} \\ \mbox{Rotação total}: & 180^{\circ} \\ \mbox{Passo angular}: & 3,000^{\circ} \\ \mbox{Tempo de contagem}: & 10s \\ \mbox{Fótons na região de feixe livre:} & 10.000 \\ \mbox{Energia:} & 60,0\mbox{ keV} \end{array}$

A partir das projeções obtidas com esses parâmetros, aplicou-se o algoritmo de reconstrução paralelo. Os valores de tons de cinza obtidos, para cada um dos cinco elementos, são apresentados na Tabela 3.2, juntamente com os valores de coeficiente de atenuação linear de cada elemento.

Elemento	Coeficiente de atenuação	Tons de cinza
Cálcio	1,001	232
Fósforo	0,748	173
Alumínio	0,631	130
Água	0,220	22
Plexiglass	0,140	11

Tabela 1. Tabela com os coeficientes de atenuação e os tons de cinza obtidos

A interface de visualização e a imagem reconstruída são apresentadas na Figura 8. Através dela é possível extrair valores de coeficiente de atenuação das amostras tomografadas.

Calculou-se, a partir desses valores, a correlação entre os coeficientes de atenuação e os tons de cinza da imagem reconstruída. O coeficiente de correlação encontrado entre as

Amostra de calibração cujos elementos e seus respectivos coeficientes de atenuação linear são conhecidos a priori

² Resina sólida de acrílico transparente de baixa atenuação que compõem os recipientes utilizados para abrigar amostras em ensaios tomográficos

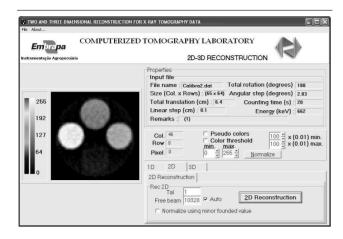


Figura 8. Janela do sistema que permite realizar a escolha da amostra tomográfica e a visualização dos cortes reconstruídos

duas variáveis foi de 0,996, mostrando que existe uma forte relação linear entre elas, tornando viável o ajuste de uma reta. Observa-se que a qualidade do ajuste da curva de calibração aos pontos observados possibilita uma boa representatividade do real coeficiente de atenuação na imagem reconstruída.

3.3. Ambientes de visualização tridimensional

Desenvolveu-se um ambiente de visualização tridimensional que tem por objetivo auxiliar a análise dos resultados e a precisão do algoritmo paralelo [17]. A ferramenta foi desenvolvida em ambiente *Windows*, utilizando o compilador *Borland Builder C++* versão 6, combinado com a biblioteca gráfica VTK, em sua versão 4.2, que foi compilada nesta mesma versão. A biblioteca VTK também fornece código-aberto para criação de um componente de renderização compatível com a biblioteca VCL do *Builder C++*, o qual pode ser inserido dentro da janela de visualização da ferramenta. A compilação deste código gera o componente de visualização TvtkBorlandRenderWindow.

A partir dos dados gerados pela reconstrução tridimensional, modelou-se um sistema de visualização para realização das análises que tem as seguintes funcionalidades:

- Visualização e interação com o objeto reconstruído;
- Conversão de arquivos de corte em arquivos .vtk;
- *Threshold* do objeto 3D, ajustando limiares mínimo e máximo;
- Visualização de cortes Sagitais, Coronais e Transversais, ao longo do eixo X, Y e Z, respectivamente;
- Criação de projetos de reconstrução;

 Front-End para execução dos algoritmos de reconstrução 2D e 3D.

A janela principal com a visualização de objetos tridimensionais é apresentada na Figura 9. Nela, é exibida uma imagem 3D de um torrão de solo que foi reconstruído utilizando os algoritmos paralelos de reconstrução tomográfica 2D e 3D.

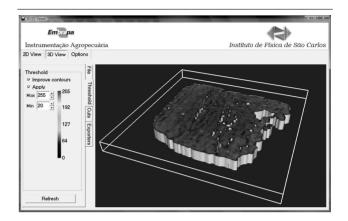


Figura 9. Interface do software de visualização onde é possível ao usuário interagir com o objeto reconstruído

A Figura 10 apresenta um corte transversal de um torrão de solo com 80 planos, do qual três medidas de coeficiente de atenuação linear foram extraídas através do modelo de visualização.

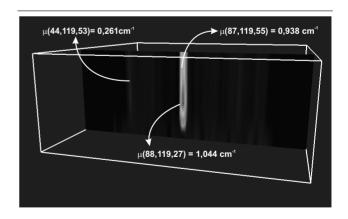


Figura 10. Medidas de coeficiente de atenuação linear de um torrão de solo, extraídas com a ferramenta

Considerando o ambiente de RV, a API Java3D adotada em todo o contexto interativo possibilitou a correta implementação dos recursos descritos e a construção do Grafo de Cena, representando todo o sistema e seus requerimentos.

De acordo com o processo de importação, o qual visa trazer a implementação da reconstrução tridimensional para o sistema de visualização por realidade virtual, o modelo reconstruído pode ser tratado por todos os conceitos anteriormente descritos. Assim, o modelo reconstruído, gravado sob o formato *Wavefront File Format* (.obj), pôde ser trazido ao sistema pelo *Loader*, preservando todas as características originais da amostra.

Visando uma completa manipulação dos objetos, as transformações físicas e a manipulação mostraram-se recursos amplamente interativos, transformando entradas de mouse e teclado nos *feedbacks* visuais esperados. Assim, através de novos parâmetros, o usuário pode esticar, mover e girar os modelos estaticamente. Paralelamente, todas as amostras podem ser rotacionadas, transladadas e escaladas para qualquer parte por meio de movimentos de mouse. Conforme o usuário escolhe o objeto na cena, a matriz de transformação é atualizada e exibida em tempo real, alem dos outros dados disponíveis.

O modelo apresentou informações precisas e práticas através de seleções por mouse, uma vez que traz à cena, através de instâncias PickCanvas e PickResult, a informação exata sobre um voxel específico, sob os dois aspectos mencionados. A operação de picking estabiliza um nível de coordenada z na tela e deixa o usuário selecionar o ponto de forma bidimensional, de maneira intuitiva. A Figura 11 apresenta o resultado da obtenção de informações de uma amostra de solo degradado. A utilização da P5Glove demonstrou resultados satisfatórios, provendo ao usuário informações precisas sobre a posição e a orientação do dispositivo, mesmo sem a calibração original fornecida. Conjuntamente, os usuários podem navegar facilmente por simples movimentos de mão, alterando o subgrafo de visualização em tempo real e analisando os voxels do mesmo modo como quando se utiliza o mouse.

Através do sistema de iluminação, todas as luzes da presente visão puderam ser alteradas em tempo real, obtendo concisos *feedbacks* visuais. Dependendo da refletância da superfície dos objetos, os efeitos dos parâmetros das fontes de luz podem variar, e como conseqüência, alterar o resultado final. Desta maneira, a disponibilidade de tais parâmetros pode também mudar, condicionada à escolha da fonte. A Figura 12 apresenta os resultados da iluminação Ambiente (a); iluminação Direcional(b). A Figura 13 apresenta iluminação Pontual (a) e (b) iluminação Pontual Angular (b), todas com cores randômicas.

O sistema de cores também contribuiu para a interatividade do sistema, uma vez que traz a possibilidade de alterar a aparência dos modelos em tempo real, retornando in-



Figura 11. Resultado da extração de atributo de uma amostra de solo

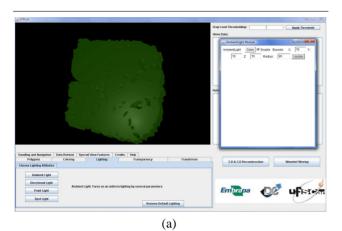
formações e respostas visuais esperadas. A interface principal provê a paleta de cores e permite ao usuário escolher a cor desejada de forma rápida e funcional. A Figura 14 mostra o resultado da aplicação do sistema de cores.

Por meio das novas opções de renderização, é fornecida uma visão analítica dos modelos na cena, permitindo aos usuários examinar os pontos e linhas gerados pelo algoritmo de reconstrução, especialmente os estimados. A Figura 15 mostra o resultado da escolha de renderização.

4. Conclusões

Os resultados demonstraram que a aplicação de algoritmos paralelos para reconstrução de imagens tomográficas contribuíu para o desenvolvimento do modelo no sentido de explorar, de forma otimizada, as características dos *hardwares* paralelos. O modelo de reconstrução paralela apresentou robustez e flexibilidade em diferentes arquiteturas paralelas. A forte correlação entre tonalidade de cinza e coeficiente de atenuação demonstrou a qualidade do algoritmo paralelo e da filtragem *a priori* na representação dos dados das amostras agrícolas.

Com relação aos resultados relacionados ao ambiente de visualização com VTK, este apresenta interatividade para análise de amostras tomográficas de solos. Ademais, permite a extração de atributos tais como coeficiente de correlação linear e densidade das amostras agrícolas.



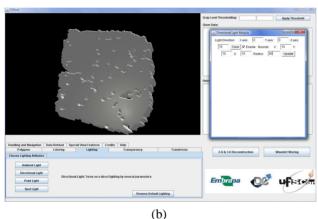
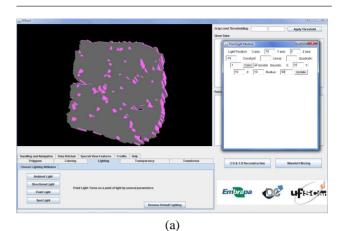


Figura 12. Resultados obtidos da aplicação do sistema de iluminação e seus respectivos parâmetros. (a) Ambiente: Fronteiras = (10, 10, 10); Raio = 90; (b) Direcional: Direção = (0, 0, 15); Fronteiras = (10, 10, 10); Raio = 90.

Com relação aos resultados do ambiente RV, eles demonstraram os *feedbacks* interativos esperados, considerando a manipulação por mouse, teclado e a luva de dados, bem como todos os processos de iluminação, renderização e colorização, os quais são cruciais para um ambiente sintético destinado à análise de modelos reais. O próximo passo será a incorporação de um vídeo-capacete ao modelo de visualização, visando atingir a imersão.

Desta maneira, nota-se a contribuição da utilização de ambientes interativos em processos não invasivos de análise e inspeção de amostras agrícolas reais. Através de tais ambientes, características internas e intrínsecas das amostras puderam ser extraídas e visualizadas, de forma mais realista que processos bidimensionais.



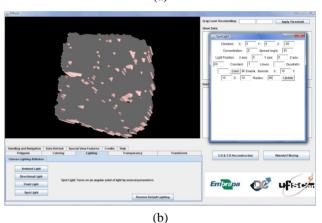


Figura 13. Resultados obtidos da aplicação do sistema de iluminação e seus respectivos parâmetros. (a) Pontual: Posição = (10, 0, -10); Atenuação Quadrática = 1; Fronteiras = (10, 10, 10); Raio = 90; (b) Pontual Angular: Direção = (0, 0, -20); Concentração = 2; Ângulo de Espalhamento = 30; Posição = (0, 0, 20); Atenuação Constante = 1; Fronteiras = (10, 10, 10); Raio = 90

Agradecimentos

Os autores gostariam de agradecer ao CNPq e Embrapa Instrumentação Agropecuária pelo apóio financeiro ao projeto.

Referências

 L. Aylmore and J. M. Hainsworth. The use of the computedassisted tomography to determine spatial distribution of soil water content. *Australian Journal Soil Res*, 21(4):435–443, 1983.

- [2] R. A. Bolt. Put-that-there: Voice and gesture at the graphics interface. In 7th International Conference on Computer Graphics and Interactive Techniques, pages 262–270, Washington, 1980.
- [3] S. Crestana. A Tomografia Computadorizada com um novo método para estudos da física da água no solo. Doutorado, Instituto de Física de São Carlos - Universidade de São Paulo, São Carlos, 1985.
- [4] E. Ferreira, A. S. de Resende, F. Balieiro, L. Zotarelli, L. A. da Silva, M. Bacis, M. A. Alfaro, B. J. R. Alves, and S. Urquiaga. Avaliação de diferentes tubos de acesso para medição da umidade do solo através do uso de sonda de nêutrons. Technical report, Empresa Brasileira de Pesquisa Agropecuária Agrobiologia, Seropédica RJ, Novembro 1998.
- [5] I. Foster. Designing and building parallel programs. Disponível on-line em http://www-unix.mcs.anl.gov/dbpp, setembro 2005.
- [6] L. Jacobson. Garage Virtual Reality. SAMS Pub, Indianapolis, Jan 1994.
- [7] A. C. Kak and M. Slaney. *Principles of Computerized Tomographic Imaging*. IEEE Press, New York, 1999.
- [8] C. Kenner. Essential reality p5glove sumary: Dual mode driver programming. Available at http://www.geocities.com/carl_a_kenner/p5.html, 2007.
- [9] Kitware Inc. VTK 5.0.2 Documentation, 2007.
- [10] J. Lanier. Visual programming languages. Scientific American. 1984.
- [11] A. Macedo, C. M. P. Váz, J. M. Naime, L. A. C. Jorge, S. Crestana, P. E. Cruvinel, J. C. D. Pereira, M. F. Guimarães, and R. Ralisch. Soil Management Impact and Wood Science - Recent Contributions of Embrapa Agricultural Instrumentation Center Using CT Imaging, pages 44–56. Embrapa - Agricultural Instrumentation, 2000.
- [12] C. Machover and S. Tice. Virtual Reality, volume 15. Jan 1994
- [13] E. R. Minatel. Modelo computacional baseado em técnicas Wavelets para relacionar imagens digitais obtidas em

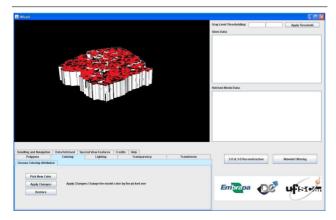


Figura 14. Resultado da aplicação do sistema de cores

- diferentes escalas e resoluções. PhD thesis, Instituto de Física de São Carlos Universidade de São Paulo, São Carlos, 2003.
- [14] E. R. Minatel and P. E. Cruvinel. Three-dimensional reconstruction and visualization of tomographic images system applied to soil analisys using b-wavelets. In E. CNPDIA, editor, *Advances in Agricultural Tomography*, pages 120–124. Paulo E. Cruvinel and Luiz A. Colnago, São Carlos, Dezembro 2000.
- [15] E. F. S. Montero and D. J. Zanchet. Realidade virtual e a medicina. Acta Cirurgica Brasileira, 18(8):489 – 490, 10 2003.
- [16] A. Pedrotti, E. A. Pauletto, S. Crestana, P. E. Cruvinel, C. M. P. Vaz, J. M. Naime, and A. Macedo. Tomografia computadorizada aplicada a estudos de um planossolo. *Pesquisa Agropecuária Brasileira*, 38(7):819–826, jul 2003.
- [17] M. F. L. Pereira. Um modelo de reconstrução tomográfica 3D para amostras agrícolas com filtragem de Wiener em processamento paralelo. PhD thesis, Instituto de Física de São Carlos - Universidade de São Paulo, São Carlos, Junho 2007.
- [18] K. Pimentel and K. Teixeira. Virtual Reality through the new looking glass. McGraw-Hill, New York, 2nd edition, 1995.
- [19] E. Reality. P5glove specification. Available at http://www.inition.com, 2007.
- [20] I. Sun Microsystems. Java 3d 1.3 api documentation. Available at http://java.sun.com/products/javamedia/3D>, 2006.
- [21] C. F. A. Teixeira, S. O. Moraes, and M. A. Simonete. Desempenho do tensiômetro, tdr e sonda de nêutrons na determinação da umidade e condutividade hidráulica do solo. *Re*vista Brasileira de Ciência do Solo, 29:161–168, 2005.
- [22] S. M. Vanni. Modelos de Regressão: Estatística Aplicada. Legmar Informática & Editora Ltda, São Paulo, 1998.
- [23] L. Velho and K. Perlin. B-spline wavelet paint. Revista de Informática Teórica e Aplicada (RITA), IX(2):100–119, Outubro 2002.
- [24] Wavefront. Wavefront File Format Specification. Wavefront Tech, 2006.



Figura 15. Resultado da aplicação de nuvem de pontos sobre uma amostra de solo

Uso de Imagens Digitais em Mensurações de Coeficientes Técnicos Agropecuários

Fábio Diniz Rossi, Claudino Andrighetto, Otoniel Geter Lauz Ferreira
Unidade de Ensino Descentralizada de Santo Augusto
Centro Federal de Educação Tecnológica de Bento Gonçalves
Rua Batista Andrighetto, 1100
Santo Augusto – RS – Brazil
{fdrossi, candrighetto, oglferreira}@cefetbg.gov.br

Resumo

Na agropecuáia, a medição de áreas é de grande importância em estudos sobre crescimento e melhoramento vegetal e animal, permitindo a seleção de plantas mais eficientes e/ou melhores ajustes nas taxas de produção animal. Entretanto, nenhuma das atuais técnicas de medição de áreas através de imagens digitais é satisfatória, pois exigem intervenções manuais na preparação ou mesmo na edição das imagens. Neste artigo, apresentamos um sistema computacional, que visa à automatização e praticidade na determinação de áreas baseadas em imagens digitais e que, de maneira simples, rápida e de baixo custo, possibilita a visualização de relatórios que possibilitam análises acerca dos objetos de estudo.

1. Introdução

A utilização da informática na agricultura (agroinformática) vem a cada dia mais demonstrando sua importância, melhorando a produtividade nas culturas através de *softwares* de modelagem e apoio à tomada de decisão.

Embora exista esse crescimento da tecnologia, a utilização em propriedades rurais é restrita, pois ainda é difícil justificar a utilização da informática pelo retorno financeiro agregado a sua utilização [16].

Sistemas de fácil manipulação e baixo custo tendem a modificar essa realidade, pois não oneram gastos em *software* nem em treinamentos, viabilizando o contato entre a produção rural e os meios tecnológicos que possibilitam crescimento de suas produções.

Este *software* proporciona a medição de dois índices relevantes para análises agropecuárias, que são: índice de área foliar (IAF) [3] e área de olho de lombo (AOL) [9], de forma automatizada, rápida e de fácil manipulação.

Esta forma automatizada se da através da utilização da computação gráfica. O conceito primeiro sobre computação gráfica a definia como o conjunto de técnicas e métodos utilizados para converter dados para um dispositivo gráfica via computador, porém hoje em dia, computação gráfica é mais do que isso, consise nas técnicas de transformação de imagens e reconhecimento de padrões.

Transformações de imagens que visam melhorar as características visuais da imagem, por exemplo contraste, foco ou distorções. Reconhecimento de padrões buscnado isolar e identificar componentes de uma imagem a partir de sua representação visual.

Baseado nas capacidades desta tecnologia, criamos um sistema computacional apto a analisar as imagems digitais as quais se propõe, de maneira ágil e prática, primando pela simplicidade e adaptação às novas aquiteturas de *hardware*.

A grande diferença entre a análise de imagens de AF e AOL é que as primeiras são compactas, necessitando de correções por inundação apenas em pequenos setores da imagem, enquanto a imagem de AOL expressa apenas o contorno da área, necessitando maior processamento para análise do polígono.

O objetivo deste artigo é apresentar um sistema computacional que utilize imagens digitais para determinar a AF, e consequentemente o IAF e AOL de maneira automatizada com facilidade e velocidade de resposta.

2. Estado da Arte

Quase toda a energia disponível para os humanos é derivada da transformação da energia solar que chega até o nosso planeta. Parte dessa energia é usada pelos organismos fotossintetizantes, sendo transformada em compostos

orgânicos através da combinação do dióxido de carbono da atmosfera com água.

O processo fotossintético é a base de toda a produção de biomassa vegetal que permite a sustentação dos organismos heterotróficos, entre eles dos seres humanos. Diante dessa importância, aumentar a eficiência fotossintética da produção vegetal passa a ser fundamental, tanto através do melhoramento genético das espécies, como no aprimoramento nas técnicas de cultivo que permitam aos vegetais melhorar seu desempenho.

Dentre essas técnicas, o IAF, que é compreendido como uma expressão da densidade populacional, dado pela área foliar (AF) existente em relação à superfície do solo, conceito de grande utilidade no manejo das culturas, especialmente para as forrageiras. Um exemplo da imagem que pe submetida ao processamento do sistema desenvolvido, é exibida na Figura 1 [5].

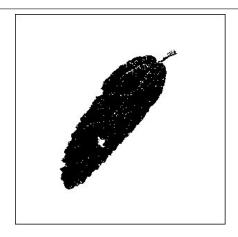


Figura 1. Imagem de referência para área foliar.

Entretanto, o conhecimento do conceito e/ou a constatação de sua importância tem utilidade prática limitada. Para uma utilização plena do potencial de manejo que esse instrumento permite, é importante a mensuração e determinação do índice de área foliar que se encontra o vegetal cultivado em um determinado momento.

Já a AOL consiste em imagens transversais do músculo *Longissimus dorsi* (Figura 2). Esta é considerada uma medida representativa da quantidade, qualidade e distribuição das massas musculares, pois músculos de maturidade tardia são indicados para representar um índice mais confiável sobre o desenvolvimento e tamanho do tecido muscular [15].

Essa medida pode ser obtida de diversas maneiras. De forma expedita, através do uso de planímetro manual, com uso de integradores eletrônicos, equipamentos normalmente de alto custo e assim de difícil aquisição e, mais recente-

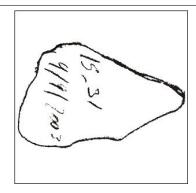


Figura 2. Imagem de referência para área de olho de lombo.

mente, com o uso de imagens digitais, onde o *software* mais conhecido é o Siarcs.

A utilização de imagens digitais possibilita a sua modificação de várias maneiras, portanto, estruturas podem ser destacadas por subtração, realce de bordas ou valores máximos/mínimos (windowing). Então, as imagens digitais são representações em duas dimensões de uma imagem como um conjunto finito de valores digitais. Esses valores digitais formam uma matriz onde cada ponto é associado a um valor. Com base nesse valor, podemos realizar análises sobre o espaço dessa imagem e realizar qualquer tipo de cálculo espacial, dentre eles o cálculo de áreas das imagens.

2.1. Siarcs

O Siarcs (Sistema Integrado para Análise de Raízes e Cobertura de Solo) é um *software* nacional que analisa área de raízes, cobertura vegetal e AF. Foi desenvolvido pela Embrapa (Empresa Brasileira de Pesquisa Agropecuária), que tem por missão viabilizar soluções para o desenvolvimento sustentável do espaço rural, com foco no agronegócio, por meio da geração, adaptação e transferência de conhecimentos e tecnologias, em benefício de diversos segmentos da sociedade brasileira [2].

Porém, este sistema exige que o usuário selecione a área da imagem que deve ser visualizada, utilize filtros em linhas internas da imagem e ajustes de escala, pois o *software* não reconhece automaticamente a definição em *pixels* (resolução) da imagem digital.

Por fim, transforma a imagem digital resultante em um vetor de valores binários, e chega ao cálculo de áreas através da soma dos valores mais significativos. Tal técnica computacional não é considerada otimizada, pois o tamanho do vetor aumenta exponencialmente dependendo do tamanho da imagem, aumentando enormemente o processamento.

Portanto, o déficit no desempenho do Siarcs não se deve a sua engenharia de *software*, pois é perfeito ao que se propõe realizar que são as medições de áreas para análises de raízes e solos, mas principalmente às intervenções manuais para correções acerca da interpretação da imagem, luminosidade e tamanho real do objeto com a utilização de *softwares* de tratamento de imagem, o que onera tempo se comparado a um sistema que faz todas as correções necessárias em tempo de execução e sem intervenção humana.

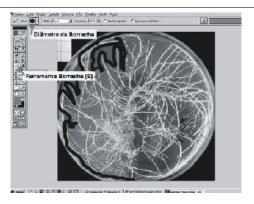


Figura 3. Tratamento manual em imagem digitalizada.

Como podemos acompanhar na Figura 3, notamos a manipulação que deve-se aplicar sobre a imagem para que o *software* Siarcs possa interpretar a área da raíz, neste caso específico.

As técnicas de analise utilizadas no Siarcs mostram-se úteis para analises de crescimento de plantas, medidas de fotossíntese e transpiracao, de herbivoria, e de doencas foliares.

Em sua última versão opera em ambiente *Windows*, onde pode ser notado um desenvolvimento em sua programação no que diz respeito às cores das imagens digitalizadas, pois em versões anteriores era limitado a apenas 16 cores.

Hoje em dia o Siarcs é capaz de se utilizar entre 256 e 16 milhoes de cores, sem contar que a própria interface do sistema mudou, tornando-se mais amigável e incrementando alguns objetos que proporcionam a manipulação das imagens e do próprio sistema mais fácil, tais como: barras de rolagem, *zoom*, ferramentas para selecao, visualizacao da paleta de diferentes formas. Ainda, as suas rotinas de processamento foram melhoradas, tais como: selecao de *pixels*, binarização, dentre outras.

3. DDA

O software então denominado DDA (Determinador Digital de Áreas) foi desenvolvido na Unidade de Ensino Descentralizada de Santo Augusto-RS do Centro Federal de Educação Tecnológica de Bento Gonçalves-RS, que contempla cursos Técnicos na área Agropecuária (agropecuária, zootecnica e agroindústria) e curso superior em Tecnologia de Agronegócios, o que possibilita utilização didática do DDA.

A diferença principal entre o DDA e outros *softwares* com a mesma função, consiste em que esses geram a partir da imagem um vetor binário do tamanho da imagem, fazendo uma leitura seqüencial até o final do vetor. Por sua vez, o DDA gera vários vetores menores, um para cada linha, e consegue através de processamento paralelo (*threads*) ler várias linhas ao mesmo tempo.

Além disso, se utiliza de técnicas de computação gráfica [12] para determinar tamanho e definição da imagem automaticamente, algoritmos para ajuste de ruídos na imagem e técnicas de análise específicas para polígonos não-convexos, o que torna o DDA uma ferramenta completa para análise de IAF e AOL.

3.1. Aquisição e Tratamento de Imagens

As imagens são adquiridas através de um *scanner*, onde se pode gerar um arquivo de imagens únicas ou vários arquivos de imagens. A preferência é que essas imagens digitalizadas sejam adquiridas e salvas em formato BMP (*Windows Bitmap*) monocromático (amplamente utilizado em plataformas *Windows*). Em oposição às imagens vetoriais, as imagens *bitmap* são imagens que contém a descrição de cada *pixel*, o que torna o tratamento deste tipo de imagem especializado, envolvendo interpolação e álgebra matricial.

Embora exija tratamento com cálculos complexos, a medição de áreas é fácil pois os pontos da imagem tem tamanhos fixos, possibilitando cálculos de área precisos e rápidos.

Baseado nessa fácil manipulação, uma das grandes vantagens do DDA é a sua capacidade de reconhecer a definição da imagem digitalizada, o que proporciona uma automatização no sentido que não é mais necessário incluir manualmente a escala das imagens [4].

Imagens ao serem digitalizadas sofrem processo de amostragem (*sampling*) que gerará, para cada linha da mesma, uma sequência de valores representando pequenos pedaços da mesma. Estes pedaços lembram um mosaico de pequenas partes de mesmo tamanho, alinhadas lado a lado [18].

Assim como em uma mosaico de pequenas partes, onde cada uma possui uma única cor, independente das demais

e no conjunto, ao serem observadas à distância formam determinada figura. Na imagem digitalizada também ocorre o mesmo: cada pedaço da imagem recebe o nome de pixel (palavra formada a partir de *picture element*) e é individualmente representada numericamente (porcentagens de cada cor básica e luminosidade).

A proporção entre a altura e a largura dos pixels que compõem uma imagem digital é chamada *pixel aspect ratio*, e imagens obtidas através de *scanners* e imagens geradas dentro do próprio computador (através de softwares gráficos por exemplo) possuem normalmente *pixels* quadrados [1].

O número que indica o valor do *pixel aspect ratio* é a medida da largura do *pixel* para uma altura padrão de uma unidade. Assim por exemplo, o formato DV (formato digital utilizado no segmento semi-profissional) no padrão NTSC (*National Televison Standards Committee*) possui *pixel aspect ratio* de 0,9 porque seus *pixels* possuem 0,9 unidades de largura para uma altura de 1 unidade.

Sendo assim, sabendo o número de *pixels* existentes no interior de uma imagem, podemos definir qual a área em centímetros da mesma.

Essas imagens devem ser importadas pelo DDA, e todo o processo é realizado automaticamente, sem a necessidade de manipulações manuais por parte do usuário, até a emissão do relatório final.

Apresentamos a seguir, todo o processamento das imagens que o DDA realiza.

3.2. Anti-aliasing

O primeiro tratamento que o DDA realiza automaticamente nas imagens importadas do *scanner* é chamado *anti- aliasing*.

Aliasing (serrilhamento) [6], é o efeito em forma de serra que se cria ao desenhar uma reta em diagonal (Figura 4 - a). Para correção dessa imperfeição nas imagens, um algoritmo de *anti-aliasing* [19] é executado internamente, e consiste em verificar todos os *pixels* mais claros da imagem e pintá-los de branco, e todos os *pixels* mais escuros da imagem em preto (Figura 4 - b).

Isso possibilita ajustar ruídos e imperfeições nas imagens digitalizadas, permitindo assim, que o algoritmo de preenchimento consiga diferenciar as bordas das imagens viabilizando um melhor somatório das áreas ds imagens digitalizadas.

3.3. Inundação de Contorno para Análise de AOL

Alguns ruídos nas bordas das imagens ou mesmo falhas na área de leitura do *scanner* ocorrem. Para tratar-

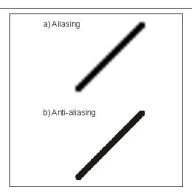


Figura 4. Efeito de Serrilhamento.

mos esses problemas utilizamos a técnica de inundação (seed-fill) [10]. Neste caso, todos os pixels vizinhos a um pixel inicial com características parecidas (magnitudes e direções próximas) recebem um mesmo rótulo (cor preta). Essa técnica também é utilizada para tratarmos algum defeitos no interior das imagens digitalizadas, o que em trabalhos futuros poderá ser utilizado para avaliarmos áreas de plantas atacadas por pragas ou doenças, como podemos ver na Figura 5, em comparação com a Figura 1. Notamos que exisitiu um preenchimento em ruídos do interior da folha para o cálculo da área.

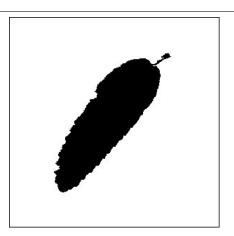


Figura 5. Imagem IAF inundada.

Isso possibilita que contornos das imagens digitalizadas não tenham linhas duplas devido à falhas de digitalização, o que iria proporcionar erros na verificação por paridade, que define se um *pixel* está dentro ou fora da imagem que deve ser mensurada [14].

3.4. Verificações por Paridade

Um grande problema na área de computação gráfica é no tratamento de polígonos não-convexos no que diz respeito a saber computacionalmente se um *pixel* se encontra no interior ou não deste polígono. Essa informação é de interesse para o DDA, pois é necessário saber automaticamente qual a localização de cada *pixel*, o que proporciona a integralização das áreas correspondentes às imagens.

Essa informação é determinada através da verificação de paridade com a utilização do algoritmo *scanline-fill* [20], que consiste em traçar uma linha sobre o polígono até um ponto P. Se o número de intersecções dessa linha até o ponto P for ímpar, então o ponto está dentro do polígono (Figura 6 - a). Se o número de intersecções dessa linha até P for par, então o ponto está fora do polígono, como podemos acompanhar na Figura 6 - b.

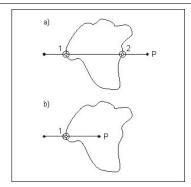


Figura 6. Paridade.

Assim, o DDA consegue determinar quais *pixels* são significativos para o cálculo das áreas das imagens e quais não o são. Para IAF, esta técnica não é muito utilizada, pois as imagens são compactas, porém quando tratamos de AOL, onde as imagens são apenas contornos, essa técnica é decisiva na verificação das imagens.

3.5. Paralelismo do DDA

A soma de computação gráfica e processamento paralelo é um diferencial do DDA, pois possibilita a resolução deste problema em específico com maior precisão em todas as fases do processo, tornando o *software* otimizado e eficiente [8].

A utilização de técnicas de processamento paralelo está cada vez mais presente em nossos computadores pessoais, pois processadores com vários *cores* (núcleos) [7]tornaramse equipamentos de baixo custo e de fácil aquisição. Porém, esses computadores são equipados com processadores que realizam mais de uma tarefa ao mesmo tempo, se e somente

se, o sistema a utilizar esse tipo de arquitetura esteja preparado para executar em vários núcleos ao mesmo tempo (Figura 7).

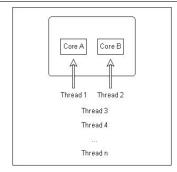


Figura 7. Arquitetura de Processadores Multicore.

Existe um senso comum sobre aplicações em processadores *multi-cores*, que todas as aplicações tem ganho significativo de processamento, porém essa informação pe falsa. Somente aplicações desenvolvidas para trabalhar com multi-processamento vai se utilizar desse novo tipo de tecnologia, chegando ao ponto de processadores *multi-core* desligarem um segundo *core* para poupar energia devido a aplicações sequenciais que não utilizam *threads*.

Essa utilização de processadores *multi-cores* [11] é feita através de técnicas de processamento paralelo chamadas *th-reads* [13], que são processos leves que embora ocupem a mesma área de memória, alocam *cores* em paralelo, otimizando cálculos pois executam ao mesmo tempo.

Essa técnica de multi-programação (threads) é utilizada na leitura sobre as imagens digitalizadas, pois como vimos anteriormente, sistemas que realizam o mesmo processo transformam as imagens em vetores binários e se movem seqüencialmente no vetor, integralizando a área da imagem dessa forma.

No DDA, a imagem é distribuída em vários vetores menores, e várias *threads* lêem esses vetores paralelamente, então, o processamento paralelo possibilita a leitura de vários vetores ao mesmo tempo, como acompanhamos na Figura 8.

Isso possibilita um ganho global de desempenho no processamento da imagem, pois ao invés da execução sequencial de apenas 1 processo por vez, a troca de contexto no acesso aos processadores é mais rápida, não deixando os processadores ociosos enquanto existirem imagens a ser processadas [17] em vários *cores* ao mesmo tempo.

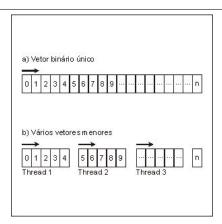


Figura 8. Vetor Binário Sequencial x Vários Vetores Menores em Paralelo.

4. Validação

Para validar o DDA como uma solução robusta para análise de IAF (pois o Siarcs não faz mensuração de AOL), comparamos o seu funcionamento com o Siarcs, que atualmente é o *software* indicado para esse fim, e que vem sendo amplamente utilizado tanto no meio empresarial quanto na academia.

Não demonstraremos comparações de precisão dos valores das áreas, pois como os dois *softwares* se utilizam de medições binárias sobre *pixels*, o valor final do cálculo de áreas é exatamente o mesmo, porém mostraremos as vantagens do DDA quanto ao tempo de processamento de um grande número de imagens a ser processadas.

Essas comparações levam em conta o número de imagens, tamanho das imagens, tempo dispendido na preparação das imagens, e tempo total de processamento.

Nos testes executados, o número de imagens variou entre 10 e 50 (10, 20, 30, 40 e 50 imagens). Estas imagens tem em média individual 200 *kilobytes*, o que proporciona além de uma análise do ônus de preparação da imagem através de ferramentas gráficas que permitem ajustes manuais, uma análise no avanço do ônus de processamento, pois o aumento do tamanho das imagens é exponencial a tal ponto que no último ambiente temos uma carga de processamento de imagens de 10 *megabytes*.

Todos os teste foram realizados em um computador equipado com um processador *dual core*, que vem a possibilitar a utilização de processamento *multi-thread*, um dos diferenciais do DDA, adaptado às novas realidades da computação atual.

4.1. Comparações

Como já citamos anteriormente, foram utilizados diferentes ambientes para a comparação entre os sistemas e, podemos acompanhar algumas vantagens do modo de operação do DDA frente ao Siarcs, algumas delas são:

- não necessita de pré-processamento;
- permite processamento multi-thread.

O DDA não necessita de ajustes nas imagens antes da medição das áreas através do sistema, como o Siarcs necessita. Essa é notadamente a grande vantagem da utilização do DDA frente às outras soluções gráficas, pois foi desenvolvido para automatizar todo o processo sem intervenção do usuário. Toda a leitura da imagem, somada a obtenção de características da imagem (como definição e tamanho), reconhecimento de traços e diferença de cores e tons, são realizadas pelo próprio DDA, através da utilização das técnicas de computação gráfica.

Podemos acompanhar na Tabela 1 (Im. = quantidade de imagens, Tam = tamanho total destas imagens em *megabytes*, TM = tempo utilizado em correções manuais, TP = tempo efetivo de processamento destas imagens pelo sistema e TT = tempo total desde intervenções manuais somado ao tempo de processamento, até a geração de relatório final).

Im.	Tam.	TM	TP	TT
10	2 MB	300 seg.	20 seg.	320 seg.
20	4 MB	720 seg.	42 seg.	762 seg.
30	6 MB	1080 seg.	71 seg.	1151 seg.
40	8 MB	1560 seg.	105 seg.	1665 seg.
50	10 MB	1920 seg.	132 seg.	2052 seg.

Tabela 1. Teste Siarcs - IAF

Podemos notar então, que o grande ônus do Siarcs se encontra nas intervenções para correções manuais que o usuário deve aplicaro sobre as imagens digitais que devem ser processadas pelo sistema.

Por si só, a utilização destas técnicas mostra um ganho de tempo notável, pois em ambientes com um grande número de imagens, torna-se oneroso ao usuário manipular todas as imagens, preparando estas, para a leitura pelo Siarcs, o que não é necessário no DDA.

Na Tabela 2 podemos analisar que além do ganho do tempo de manipulação das imagens, que inexiste no DDA, temos um ganho significativo através da utilização de processador específico para processamento paralelo.

Mesmo que o DDA seja utilizado em um computador que não seja equipado com este tipo de processador, o ganho pela utilização das técnicas de computação gráfica é um

Im.	Tam.	TM	TP	TT
10	2 MB	0 seg.	12 seg.	12 seg.
20	4 MB	0 seg.	19 seg.	19 seg.
30	6 MB	0 seg.	31 seg.	31 seg.
40	8 MB	0 seg.	48 seg.	48 seg.
50	10 MB	0 seg.	61 seg.	61 seg.

Tabela 2. Teste DDA - IAF

diferencial, o que valida o DDA como uma solução bastante robusta na medição de índices agropecuários.

5. Conclusões

A medição de coeficientes técnicos agropecuários vem demonstrando sua importância, pois possibilita um melhor ajuste nas taxas de produção. Com o advindo da computação, podemos nos utilizar das novas tecnologias para automatizar o acesso a esses índices, possibilitando uma otimização no tempo de resposta voltado ao desenvolvimento vegetal/animal.

Porém, o que nota-se é que sistemas de computação vem evoluíndo exponencialmente em várias áreas do conhecimento, porém em áreas agrícolas esse crescimento da tecnologia no que diz respeito à sistemas vem voltando seu interesse apenas nos útlimos anos, e isto se deve principalmente a um incremento da utilização do computador como ferramenta de auxílio nas produções agropecuárias.

Portanto, muitas metodologias e equipamentos tradicionais estão sendo substituídos por sistemas eletrônicos, que otimizam as análises de dados rurais. Uma destas tecnologias é a computação gráfica, que através da utilização de imagens digitais, proporciona ao produtor uma verificação em tempo real do desenvolvimento de sua produção.

Inserido nesse meio, desenvolvemos o DDA, sistema de determinação de áreas, até o momento desenvolvido para determinação de índice de área foliar (IAF) e área de olho de lombo (AOL), que por ter sido desenvolvido de forma modular, permite como trabalhos futuros a adição de novos parâmetros de medição agropecuária.

O DDA se mostra válido, tanto pela sua facilidade de utilização quanto pela sua agilidade. A sua facilidade de utilização se deve a não necessidade de intervenções do utilização, que apenas deve capturar as imagens digitais através de meio ótico (no momento, especificamente o *scanner*) e importar no DDA essa lista de imagens digitalizadas, não percisando intervir mais no processo.

A sua agilidade vem da computação gráfica aliada a técnicas de processamento paralelo. As técnicas de computação gráfica possibilitam uma melhor leitura sobre as imagens, proporcionando rapidez na leitura das áreas e dimensões das imagens. Já as técnicas de processamento paralelos incrementadas ao DDA, possibilitam que em computadores equipados com processadores que possibilitem processamento paralelo (processadores *dual core*, *core duo*, *core 2 duo*, *quad core*, o DDA aumente a otimização no processamento das imagens digitais.

Isto mostra que o DDA está preparado e adaptado às novas tecnologias que estão surgindo, um dos seus diferenciais.

Referências

- [1] volume 1, Brooklyn, NY, USA. Pixel Communications, Inc.
- [2] http://www.embrapa.br, Acessado em 20/07/2008.
- [3] N. Bréda. Ground-based measurements of leaf área index: a review of methods, intruments and current controversies. pages 2403–2417, 2003.
- [4] K. W. Brodlie. Computer graphics for scientific computing, pages 187–201, 1990.
- [5] A. Caruzzo and H. Rocha. Estimativa do índice de área foliar (iaf) em regiões de pastagem e floresta com um método indireto (gap fraction) durante o experimento amc/lba. pages 2478–2485, 2000.
- [6] P. W. Cattaneo. The anti-aliasing requirements for area and timing measurements in sampled systems. *Signal Process.*, 82(3):407–416, 2002.
- [7] T. Constantinou, Y. Sazeides, P. Michaud, D. Fetis, and A. Seznec. Performance implications of single thread migration on a chip multi-core. SIGARCH Comput. Archit. News, 33(4):80–91, 2005.
- [8] F. C. Crow. Parallel computing for graphics. In Advances in Computer Graphics VI, Images: Synthesis, Analysis, and Interaction (Tutorials from Eurographics'90 Conf.), pages 113–140, London, UK, 1991. Springer-Verlag.
- [9] B. Golden. Genetic parameter estimates of ultrasound-measured longissimus muscle area and 12th rib fat thickness in brangus cattle. pages 2623–2630, 1993.
- [10] P. S. Heckbert. A seed fill algorithm. pages 275–277, 1990.
- [11] R. Kumar, V. Zyuban, and D. M. Tullsen. Interconnections in multi-core architectures: Understanding mechanisms, overheads and scaling. SIGARCH Comput. Archit. News, 33(2):408–419, 2005.
- [12] P. G. Mccrea. Raster scan computer graphics and incremental computing systems. PhD thesis, New South Wales, Australia, Australia, 1976.
- [13] K. Schwan, H. Zhou, and A. Gheith. Real-time threads. *SI-GOPS Oper. Syst. Rev.*, 25(4):35–46, 1991.
- [14] C. D. Shaw, J. A. Hall, D. S. Ebert, and D. A. Roberts. Interactive lens visualization techniques. In VIS '99: Proceedings of the conference on Visualization '99, pages 155–160, Los Alamitos, CA, USA, 1999. IEEE Computer Society Press.
- [15] H. Shepard. Genetic parameter estimates of live animal ultrasonic measures of retail yield indicators in yearling breeding cattle. pages 761–768, 1996.

- [16] S. Shur and D. Mittelberg. Agro-industrial community computerisation. *Comput. Bull.*, 1(1):22–24, 1989.
- [17] G. J. Smit, A. B. Kokkeler, P. T. Wolkotte, and M. D. van de Burgwal. Multi-core architectures and streaming applications. In *SLIP '08: Proceedings of the 2008 international* workshop on System level interconnect prediction, pages 35– 42, New York, NY, USA, 2008. ACM.
- [18] G. F. Swart. Efficient algorithms for computing geometric intersections (decision tree, hidden line removal, graphics, complexity). PhD thesis, 1985.
- [19] K. Turkowski. Anti-aliasing through the use of coordinate transformations. SIGGRAPH Comput. Graph., 16(3):19, 1982.
- [20] D. Weinstein. Scanline surfacing: building separating surfaces from planar contours. In VIS '00: Proceedings of the conference on Visualization '00, pages 283–289, Los Alamitos, CA, USA, 2000. IEEE Computer Society Press.