

Utilizando Filtragem de Kalman e Redes Neurais em uma Estimação Conjunta para Melhoria de Qualidade da Análise de Parâmetros Físicos do Solo com Tomografia Computadorizada de Raios X

Paulo Estevão Cruvinel¹
Marcos Antonio de Matos Laia²
Álvaro Macedo da Silva³

Introdução

Largamente utilizada na medicina, o uso da TC em ciência do solo foi introduzida na década de 80 (PETROVIC et al., 1982; HAINSWORTH e AYLMOORE, 1983; CRESTANA et al., 1985), onde foi demonstrado que a TC pode auxiliar diagnóstico e prognósticos da física da água no solo e sobre a distribuição espacial da densidade e da porosidade em um volume considerado.

O processo de tomografia envolve a ação de iluminar um objeto com um feixe de raios X em várias direções e armazenar o conjunto de medidas decorrentes as quais representam amostras de um conjunto de projeções. O uso do computador na tomografia é essencial para a reconstrução da imagem a partir de projeções. Rubin e colaboradores apresentaram uma completa abordagem sobre o histórico da tomografia, o estado da arte e suas tendências (RUBIN et al., 1999).

Com base na intensidade emitida por uma fonte de raios X e na intensidade captada por um detector na outra extremidade da linha 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 utilizado para o processo de reconstrução, o qual possibilita a obtenção de um mapa de coeficientes de atenuação linear¹ ou de massa da secção transversal da amostra em estudo. Cada dado armazenado é na realidade uma média de valores que traduzem a composição do material presente no caminho de propagação do feixe de iluminação.

Uma projeção tomográfica, formada com as várias amostras, é obtida com base no uso de técnicas de medidas que envolvem o sensor de raios X, um pré-amplificador, um amplificador, um mono-canal, um conversor analógico para digital, um contador e um temporizador que define a janela de contagem desejada por

amostra da projeção tomográfica a ser estruturada. Uma projeção pode ser considerada como um sinal unidimensional discreto no tempo (MADISETTI, 2008), um sinal digital, onde cada amostra da projeção apresenta uma relação (Sinal/Ruído).

O ruído é em geral associado com as medidas e pode surgir de diferentes fontes: do dispositivo de medição, dos equipamentos eletrônicos ou do próprio processo. O efeito de um ruído gerado eletricamente pode ser melhorado com a seleção adequada dos cabos, da fonte de alimentação, da conexão terra, entre outros. O ruído induzido no processo pode surgir de variadas formas, isto é, mistura incompleta, turbulências e fluxo não-uniforme. O efeito de ambas as formas do aparecimento do ruído no processo ou na medição pode ser reduzido a partir do condicionamento do sinal ou filtragem. O termo filtro está associado a uma função de transferência uma vez que o filtro transforma um sinal de entrada em outro sinal de saída (FETTWEIS, 1986).

A principal fonte de ruído em imagens TC é a variação quântica, definida como a variação estatística espacial e temporal no número de fótons de raios X absorvidos no detector. Para feixes de raios X na TC, três principais processos de interação da radiação com a amostra influenciam na atenuação do feixe. São eles os efeitos: fotoelétrico, Compton e de produção de pares. Além dos efeitos relacionados, os quais dependem da energia utilizada, a estatística da contagem de fótons é outro ponto que deve ser observado. O termo ruído na medida de coeficientes de atenuação em imagens tomográficas de raios X refere-se à variação percentual de valor em relação a um valor de referência em uma dada energia.

Neste trabalho é apresentada uma solução para a melhora da qualidade de medidas de parâmetros físicos do solo com tomografia de raios X com melhoria da relação (Sinal/Ruído) de projeções com base no uso de redes neurais para a realização de pré-filtragem e filtragem de Kalman.

¹ Coeficientes de atenuação linear - informação relacionada ao fator de atenuação de raios X ao interagir com a matéria, o qual é função da energia do feixe incidente e da composição elemental da matéria (para um absorvedor homogêneo é função do número atômico do elemento). Sua unidade de medida é cm^{-1} .

¹ Engenheiro, Dr., Pesquisador, Embrapa Instrumentação Agropecuária, C.P. 741, CEP 13560-970, São Carlos, SP, cruvinel@cnpdia.embrapa.br

² Bacharel, Mestre em Ciências da Computação, Rodovia Washington Luís, km 235, 13565-905 São Carlos, SP, marcoslaia@dc.ufscar.br

³ Engenheiro, Dr., Pesquisador, Embrapa Instrumentação Agropecuária, C.P. 741, CEP 13560-970, São Carlos, SP, alvaro@cnpdia.embrapa.br

Filtro de Kalman e Algoritmo de Suavização

A teoria do filtro de Kalman fornece equações para modificar recursivamente às estimativas de um processo desconhecido, combinando observações relacionadas com este processo e conhecimentos sobre a sua evolução temporal (HOMLEID, 1995). Tais equações foram desenvolvidas inicialmente em 1960 pelo estatístico húngaro-americano R. E. Kalman no contexto do programa americano espacial do projeto Apollo em 1969. Posteriormente, a teoria do filtro de Kalman foi aplicada a outras áreas. A teoria do filtro de Kalman é extensa e as equações básicas que descrevem a evolução temporal do processo e a relação entre preditores e preditandos segue a formulação descrita a seguir (SIMONSEN, 1991; LAIA, 2007 LAIA et al, 2007).

Seja y_t o parâmetro que se quer estimar no instante t , isto é, o preditando, que neste trabalho é a diferença entre a observação e a respectiva previsão do número de fótons medidos no sensor. O preditando está relacionado com os preditores através da equação de observação:

$$y_t = F_t m_t + v_t \tag{1}$$

onde F_t é a matriz de preditores no instante t e v_t é um vetor que dá a variação aleatória do instante $(t-1)$ até t , com média zero e variância conhecida dada por V_t . O estado do sistema no instante t está relacionado com o instante $(t-1)$ através da equação do sistema, dada por:

$$m_t = m_{t-1} + w_t \quad t = 1, 2, \dots \tag{2}$$

onde m_t é a matriz dos coeficientes dos preditores e w_t é um vetor que dá a variação aleatória do instante $(t-1)$ até t , com média zero e variância conhecida dada por W_t . A equação de observação é usada na maioria dos métodos estatísticos e é resolvida através de uma regressão linear múltipla que ajusta a melhor relação entre preditores e preditandos.

A teoria de Kalman se diferencia dos outros métodos através da equação do sistema, que permite que os coeficientes variem ao longo do tempo, ou seja:

$$\hat{y}_t = F_t m_{t-1} \tag{3}$$

\hat{y}_t é a previsão de y_t , onde m_{t-1} são os coeficientes dos preditores em $(t-1)$.

$$e_t = y_t - \hat{y}_t \tag{4}$$

e_t é o erro da previsão

$$R_t = C_t + W_t \tag{5}$$

R_t é a matriz que atualiza C_t , onde C_t é a variância dos coeficientes m_{t-1} e W_t é a variância do vetor w_t .

$$\hat{Y}_t = F_t R_t F_t^T + V_t \tag{6}$$

\hat{Y}_t é a variância de \hat{y}_t , onde V_t é a variância do vetor v_t .

$$A_t = R_t F_t^T / \hat{Y}_t \tag{7}$$

A_t é a matriz ganho de Kalman

$$m_t = m_{t-1} + A_t e_t \tag{8}$$

m_t são os coeficientes dos preditores

$$C_t = R_t - A_t \hat{Y}_t A_t^T \tag{9}$$

C_t é a variância dos coeficientes m_t

O algoritmo traduzido pelo conjunto de equações é computacionalmente implementável e possui a vantagem de ser suficiente para atualizar o filtro de Kalman do instante $t-1$ até o instante t .

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. Supondo que exista um conjunto de dados sobre o intervalo do tempo $0 \leq k \leq N$. A suavização é uma operação *off-line* que envolve a estimação do estado x_k para $0 \leq k \leq N$, usando todos os dados disponíveis, tanto passado como futuro. Assume-se que o tempo final N é fixo para determinar a estimativa do estado ótimo x_k para $0 \leq k \leq N$, e a data futura x_j definida por $0 \leq j \leq N$.

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. O filtro de informação é distinguido do filtro básico de Kalman na maneira em que ele propaga a inversa da matriz de covariância de erro, melhor do que a matriz de covariância de erro normal, o que é proporcionado com base no uso de suavização. No desenvolvimento deste trabalho foi utilizado o algoritmo de suavização de Rauch-Tung - Striebel (RTS), (SARKKA, 2008).

Rede Neural

Uma rede neural tem sua saída determinada por uma função de transferência (MCCULLOCH e PITTS, 1947) ou função limite que define a transmissão dos neurônios, que a configuram, quando excitados. Conforme ilustra a Figura 1, dois ou mais neurônios podem ser combinados em uma camada, assim como uma rede neural pode ter mais de uma camada.

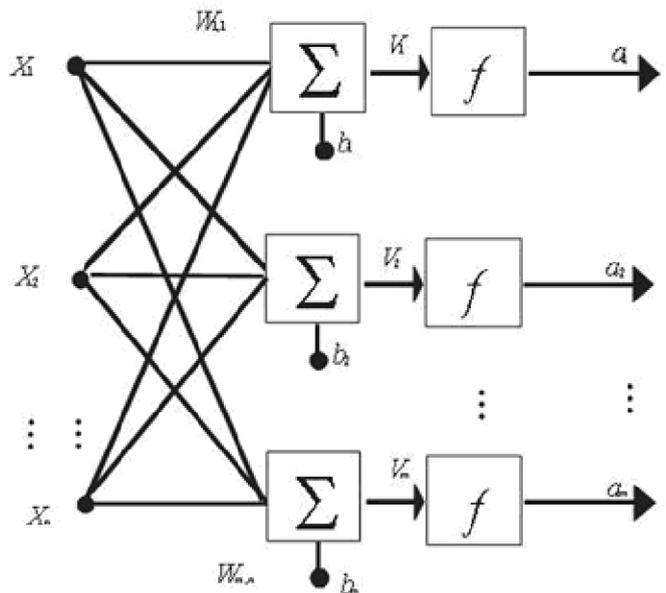


Fig. 1. Estrutura de uma rede neural com vários neurônios formando uma única camada. Várias camadas podem ser sobrepostas da mesma forma de forma a estabelecer estruturas com maior complexidade. X representa elementos do vetor de entrada.

Em uma rede neural o número de neurônios pode ser diferente do número de entradas numa camada, assim a camada não fica restrita e a matriz W tem a forma.

$$W = \begin{bmatrix} W_{1,1} & W_{1,2} & \dots & W_{1,m} \\ W_{2,1} & W_{2,2} & \dots & W_{2,m} \\ \vdots & \vdots & \vdots & \vdots \\ W_{m,1} & W_{m,2} & \dots & W_{m,m} \end{bmatrix} \tag{10}$$

Cada elemento do vetor de entrada X é conectado a cada entrada do neurônio através da matriz W . O i -ésimo neurônio tem uma soma que seu próprio peso e seu próprio *bias* para formar uma saída escalar $V(i)$. Eles por suas vezes juntamente com um neurônio m do vetor de entrada V formam a saída da camada, na forma de um vetor coluna com a informações processadas.

Modelagem para a Estimação Conjunta

Para a estimaco conjunta as equaces para predico passam a ser descritas como:

$$x_k = F x_{k-1} + W_k \quad (11)$$

A estimaco de parâmetros envolve a determinaco de um mapeamento no linear na forma:

$$y_k = G x_k + W \quad (12)$$

onde x_k é a entrada, W é o peso e y_k é a sada e o mapeamento no linear G é parametrizado pelo vetor W . O mapeamento no linear é feito por uma rede neural artificial, onde W é o peso. O aprendizado corresponde à estimaco dos parâmetros de W . O treinamento pode ser feito com pares de amostras, consistindo em uma entrada conhecida e sada desejadas (x_k, d_k) . O erro é ento definido pela equaco (13) e o objetivo do aprendizado é minimizar o erro quadrático esperado, ou seja:

$$e_k = d_k - G x_k + W \quad (13)$$

Usando um modelo para treinamento da rede como feito neste trabalho, o Filtro de Kalman Estendido (FKE) pode ser usado para estimar os parâmetros escrevendo uma nova representaco estado-espacial:

$$w_k = W_{k-1} + v_k \quad (14)$$

$$y_k = G x_k + w_k + e_k \quad (15)$$

onde os parâmetros w_k correspondem a um processo estacionário com uma matriz identidade de transio de estado, governado por um rudo processual v_k (a escolha da variância determina a qualidade da filtragem). A sada y_k corresponde a uma observaco no linear em w_k .

Como o problema em questo consiste em se trabalhar sobre uma entrada x_k no observada e requer uma uno entre a estimaco dos estados e parâmetros, deve-se considerar um problema de estimaco dual, com base em uma dinmica discreto-temporal de um sistema no linear, ou seja:

$$x_{k+1} = F x_k + v_k + W \quad (16)$$

$$z_k = H x_k + n_k \quad (17)$$

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

Assim, o sistema dinmico pode ser entendido como uma rede neural, onde W é o conjunto de pesos.

Assim, aplicando essas equaces ao filtro de Kalman estendido, tem-se uma nova funo para estimaco e para a observaco desejada.

O diagrama de blocos para a filtragem com base na modelagem considerada pode ser visto na Figura 2.

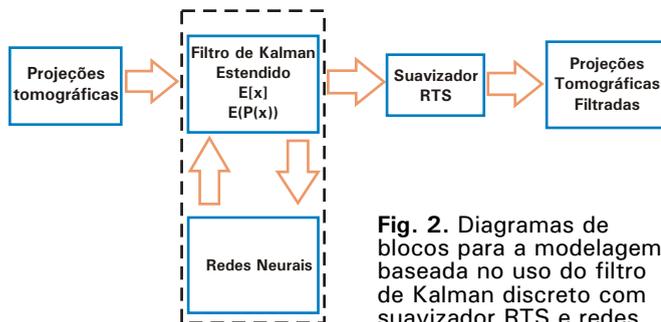


Fig. 2. Diagramas de blocos para a modelagem baseada no uso do filtro de Kalman discreto com suavizador RTS e redes neurais.

O filtro de Kalman pode receber uma funo no-linear e treinar parâmetros (pesos). Há, ento, a possibilidade de usar um mapeamento da funo com redes neurais onde o próprio filtro treina os neurnios e avança para um sistema estável onde os pesos são estimados de forma ótima e a funo mapeamento possui um menor erro. Este filtro permite trabalhar com ordens elevadas, com a preciso equivalente à terceira ordem da expanso das séries de Taylor.

Com o uso de uma rede neural pode-se promover um melhor mapeamento da funo de processo, diminuindo o rudo presente nas projees. Para uma estimaco dos pesos da rede neural em conjunto com as estimaces dos estados, pode-se utilizar duas modalidades de filtragem: a estimaco dual e a estimaco 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 na forma:

$$x_{k+1} = f(x_k) + W_k v_k \quad (18)$$

Uma forma simplificada é utilizada para a estimaco conjunta (uma variao do filtro que combina o filtro de estados aumentados com estimaco dual), em que há a possibilidade de estimar, de forma simultânea, os parâmetros necessários para a estimaco dos estados do filtro, obtendo em um único filtro a funo de estimaco e os parâmetros, garantindo uma melhor eficincia e simplificao, na forma:

$$\frac{P_i^{n+1}}{W} = \frac{f(P_i^n) + W v_k}{1 * W} \quad (19)$$

$$P_i^{n+1} = h(P_i^n) + n_k \quad (20)$$

onde P_i^n é uma projeo tomográfica considerada, w são os pesos para a funo f que é descrita como uma rede neural e I uma matriz identidade.

Avaliao de Resultados

Para a caracterizao dos resultados, um Phantom⁵ homogêneo cilndrico foi construído com um material composto de Nylon e um outro heterogêneo com base de plexiglass em forma cilndrica e capacidade para alocar outros quatro materiais para calibrao e análise, conforme ilustra respectivamente a Figura 3 em suas sees (a) e (b). Os Phantoms foram projetados com 60 mm de diâmetro, e para o heterogêneo foram estabelecidos 22 mm para o alojamento de uma amostra de Cálcio e outra de Águ, bem como 19 mm de diâmetro e as amostras de Fsforo e Alumnio. As tomografias destes corpos de prova e de amostras de solo foram imageadas utilizando tomgrafos da Embrapa Instrumentao Agropecuária (CRUVINEL, 1987; CRUVINEL et al., 1990; MACEDO DA SILVA, 1997).

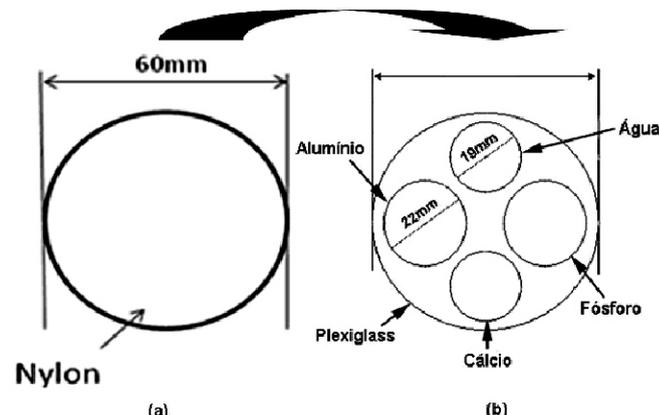


Fig. 3. Phantoms (a) homogêneo, (b) heterogêneo.

⁵Phantom Corpo de prova, construído com parâmetros conhecidos ou de referncia. É utilizado para calibrao ou caracterizao de padres ou texturas de interesse.

Para avaliação da filtragem foram utilizados os *Phantoms* e uma janela de interesse (ROI). Assim, pôde-se analisar não só o sinal da matriz de projeções como também a imagem reconstruída.

As projeções e a imagem reconstruída para os *Phantoms* homogêneo e heterogêneo sem filtragem são apresentadas na Figura 4.

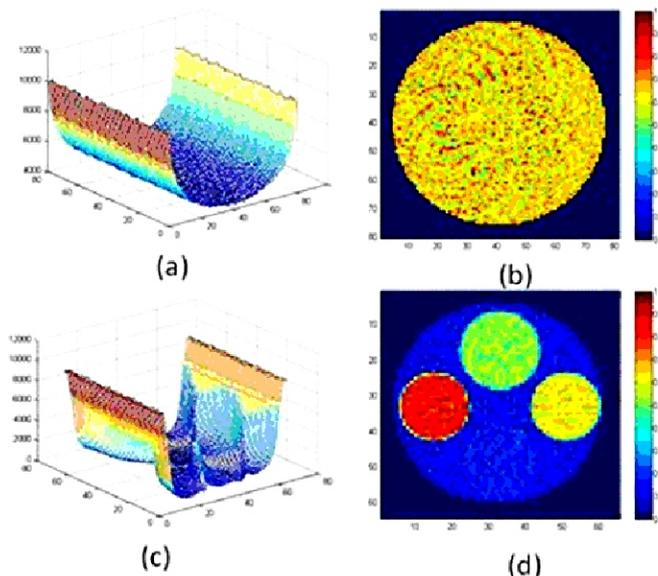


Fig. 4. *Phantoms* utilizados para calibração e validação: (a) e (b) projeções e imagem reconstruída e visualizada para o *Phantom* homogêneo com rotação em sentido horário de 90° e pseudo-cores, (c) e (d) projeções e imagem reconstruída e visualizada para o *Phantom* heterogêneo com rotação em sentido horário de 90° e pseudo-cores.

Para medir a qualidade da filtragem, foi utilizado o ISNR⁶ com base nas variâncias dos valores em janelas (ROIs) nas imagens reconstruídas. Um ISNR negativo indica a perda de detalhe ou deformação e presença de artefatos na imagem resultante. Para o *Phantom* heterogêneo, foram utilizadas cinco janelas (ROIs), uma sobre cada elemento de interesse, onde a presença de um valor negativo ou queda dos valores do ISNR indicam um resultado de pior qualidade. A Figura 5 ilustra as regiões de interesse utilizadas para a quantificação da qualidade da filtragem empregada para a melhoria na qualidade das medidas com tomografia de raios X.

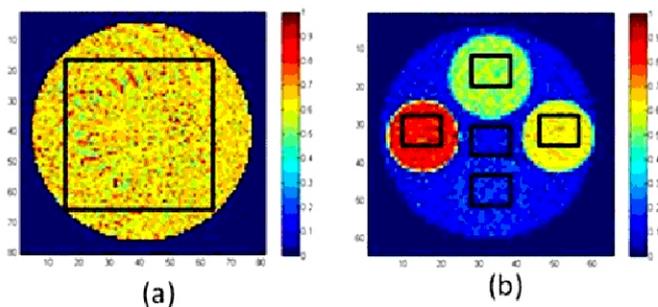


Fig. 5. Regiões de interesse para avaliar os resultados obtidos: Em (a) uma ROI de 42x28 pixels e em (b) cinco ROIs de 14x11 pixels.

A Tabela 1 apresenta resultados de análises realizadas para verificação da relação entre ISNR e a qualidade do sinal e da imagem reconstruída.

⁶ISNR Medida da relação (Sinal/Ruído) melhorada, parâmetro que indica o quanto se melhor ou não a qualidade de um sinal após a aplicação de operações para a melhoria.

Tabela 1. Resultados obtidos com o filtro de Kalman discreto para *Phantoms* homogêneo e heterogêneo respectivamente.

Variância do ruído do processo para Q=1	<i>Phantom</i> Homogêneo	<i>Phantom</i> Heterogêneo				
	ISNR Máximo (em dB)	ISNR Máximo (em dB)				
R=0,1	0,84	0,31	0,23	0,30	0,15	0,24
R=0,5	2,64	1,19	0,98	1,20	0,50	0,69
R=0,8	3,42	1,55	1,20	1,52	0,91	1,48
R=1	3,87	2,01	2,10	1,80	1,18	0,99
R=2	4,70	3,20	2,50	2,89	1,55	1,90
R=3	5,38	3,55	2,54	3,77	1,76	2,63
R=4	5,23	3,97	3,51	4,23	2,13	2,19
R=5	5,02	4,14	3,13	4,92	3,01	3,98

Um estudo com a variância do ruído do sistema foi realizado para se obter o melhor valor de ISNR para as projeções filtradas. O melhor valor de ISNR para o *Phantom* homogêneo foi de 7,23 dB para uma variância do ruído do sistema no valor de 1.000.000. A partir de 10.000, o mesmo valor da variância do ruído do processo, a melhoria foi aumentando em uma taxa menor. Para o *Phantom* heterogêneo, o melhor resultado foi obtido comparando os valores de ISNR para todas as janelas observadas, sem haver regressão nos resultados. Com essa análise, verificou-se que os melhores resultados foram de 4,15 dB, 3,43 dB, 4,05 dB, 2,98 dB e 2,49 dB, com o valor da variância do ruído do processo 10 vezes maior do que o valor da variância ruído do sistema (Q = 100.000)

Os resultados obtidos com a aplicação do filtro para ambos os *Phantoms* podem ser visualizados na Figura 6. Com base nas imagens reconstruídas, podem-se observar distorções, devido ao erro de filtragem. O algoritmo de suavização RTS adequada à variância do sinal para que esse erro seja minimizado, retornando, através de menores variâncias, melhores médias. Mesmo assim, é possível perceber uma definição melhor dos diferentes materiais na imagem do *Phantom* heterogêneo e uma variação menor no *Phantom* homogêneo.

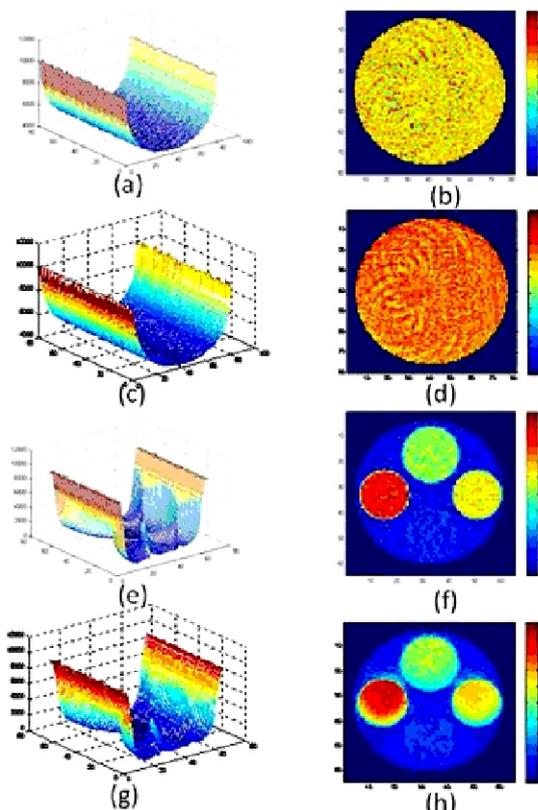


Fig. 6. Resultados com melhor qualidade obtidos com o filtro de Kalman estendido com redes neurais: (a), (b) projeções tomográficas e imagens reconstruídas para o *Phantom* homogêneo, (c) e (d) projeções tomográficas e imagens reconstruídas para o *Phantom* heterogêneo.

Uma rede neural do tipo perceptron multicamadas foi utilizada, com duas camadas, sendo a camada de entrada com apenas 2 neurônios na camada oculta com a função de transferência ou ativação sigmoideal e um neurônio na camada de saída com a função de transferência linear.

A Tabela 2 apresenta resultados de testes realizados para verificar a relação entre ISNR e a qualidade do sinal e da imagem reconstruída.

Tabela 2. Resultados obtidos com o filtro de Kalman estendido com redes neurais para os Phantoms homogêneo e heterogêneo respectivamente.

Variância do ruído do processo para $Q=10.000$	Phantom Homogêneo	Phantom Heterogêneo				
	ISNR (em dB)	ISNR (em dB)				
R=0	0,03	0,00	0,00	0,00	0,00	0,00
R=5.000	5,15	1,36	1,17	1,35	1,01	1,04
R=10.000	6,09	1,98	1,73	2,00	1,37	1,52
R=50.000	6,57	3,54	3,05	3,50	2,24	2,48
R=100.000	6,74	4,15	3,43	4,05	2,98	2,49
R=500.000	7,12	5,66	3,88	5,49	6,08	1,15
R=700.000	7,18	5,79	4,00	5,86	6,78	0,91
R=1.000.000	7,23	5,70	4,24	6,28	7,30	0,83

O resultado obtido com o filtro de Kalman estendido com redes neurais indicou valores crescentes até o valor de R igual a 4 para o Phantom homogêneo e R igual a 3 para o Phantom heterogêneo e houve uma filtragem sem a perda de detalhamento na imagem.

Aplicando a técnica com base em filtragem de Kalman discreto e estimção conjunta em uma projeção real de solo é possível perceber as distorções causadas pelo erro de estimção dos estados, dadas à presença do ruído Poisson e a complexidade dos sinais tomográficos envolvidos, conforme ilustra a Figura 7.

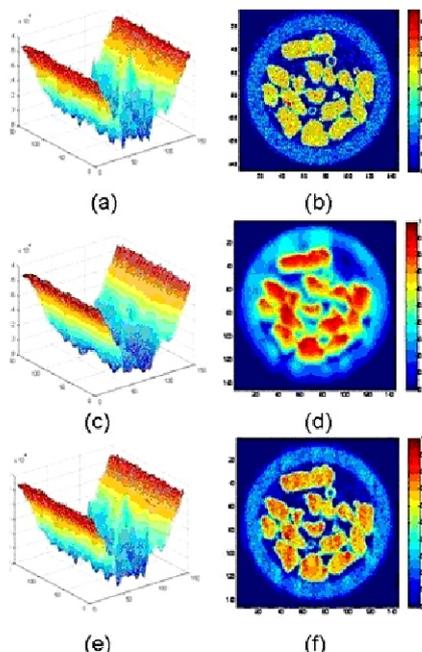


Fig. 7. Resultados obtidos com amostra de solo agrícola, onde em (a) e (b) são apresentados o conjunto de projeções tomográficas originais e a imagem reconstruída em (c) e (d) as projeções tomográficas filtradas com filtro de Kalman discreto e a imagem reconstruída, onde são observadas perdas de detalhes, borramento e perdas de informações de alta frequência e em (e) e (f), as projeções tomográficas com filtragem utilizando Kalman com redes neurais (estimção conjunta) e a respectiva imagem reconstruída, com melhor qualidade e preservação de detalhes, realce de bordas ou altas frequências e menor desvio nas medidas das informações da amostra agrícola.

Pode-se perceber que os limites das bordas na amostra de solo, em particular em função da textura apresentada em amostras desta natureza, seus detalhes na imagem reconstruída são perdidos em decorrência da pobre estimção realizada em função da filtragem utilizada que apenas guarda o resultado anterior, não estabelecendo um conhecimento a priori mais profundo. Com o uso de um filtro de Kalman com estimção conjunta, conforme modelagens desenvolvidas, em que estados podem ser usados para guardar uma dinâmica melhor do comportamento do sinal na relação de pesos, pode-se obter um resultado significativamente melhor.

Conclusões

Foi apresentado um novo modelo para a melhoria da qualidade de análises de parâmetros físicos de amostras de solos agrícolas com a técnica de TC. Para tanto, foi desenvolvido um modelo filtragem de Kalman estendido em estimção conjunta com base no uso de uma rede neural, o qual permite um mapeamento melhor das médias dos valores do sistema de medida através do uso de função não lineares.

A aplicação de redes neurais com o filtro de Kalman estendido permitiu ao filtro alcançar funções não lineares superiores. Como o filtro de Kalman pode ser utilizado para treinar redes neurais, o uso das extensões com estimção conjunta ou dual permitiu que o filtro viesse a ser completo e independente no mapeamento de qualquer função não linear, sendo adequado para a melhoria da técnica de análise nas ciências do solo.

Referências

CRESTANA, S.; MASCARENHAS, S.; POZZI-MUCELLI, R. S. Static and dynamic three-dimensional studies of water in soil using computerized tomographic scanning. *Soil Science*, Baltimore, v. 140, n. 5, p. 326-332, 1985.

CRUVINEL, P. E. **Minitomógrafo de raios X e raios gama computadorizado para aplicações multidisciplinares.** 1987. 329 f. Tese (Doutorado) - Universidade Estadual de Campinas, Campinas.

CRUVINEL, P. E.; CESAREO, R.; CRESTANA, S.; MASCARENHAS, S. X and γ -ray computerized minitomograph scanner for soil science. *IEEE Transactions on Instrumentation and Measurement*, New York, v. 39, n. 5, p. 745-750, 1990.

FETTWEIS, A. Wave digital filters: Theory and practice. *Proceedings of the IEEE*, New York, v. 74, n., p. 270-327, 1986.

HAINSWORTH, J. M.; AYLMOORE, L. A. G. The use of the computed-assisted tomography to determine spatial distribution of soil water content. *Australian Journal of Soil Research*, Melbourne, n. 21, p. 1435-1443, 1983.

HOMLEID, M. Diurnal corrections of short-term surface temperature forecasts using the Kalman filter. *Weather and Forecasting*, Boston, v. 10, p. 689-707, 1995.

LAIA, M. A. M. **Filtragem de projeções tomográficas do solo utilizando Kalman e Redes Neurais.** 2007. Dissertação (Mestrado) - Universidade Federal de São Carlos, São Carlos

LAIA, M. A. M.; CRUVINEL, P. E.; LEVADA, A. L. M. Filtragem de projeções tomográficas da ciência do solo utilizando transformada de Anscombe e Kalman. In: BRAZILIAN CONFERENCE ON DYNAMICS, CONTROL AND THEIR APPLICATIONS - DINCON' 2007, 6., 2007. São José do Rio Preto, SP. *Proceedings...* Rio Claro: UNESP, 2007. 1 CD-ROM. p. 1226-1233. Anais.

MACEDO DA SILVA, A. **Construção e uso de um tomógrafo com resolução micrométrica para aplicações em Ciências do Solo e do Ambiente.** 1997. 129 f. Tese (Doutorado) - Universidade de São Paulo, São Carlos.

MADISSETTI, V. (Ed.). **The Digital Signal Processing Handbook.** 2nd ed. [S. l.]: CRC, 2008. ISBN: 1420045636

MCCULLOCH, W. S.; PITTS, W. How we know universals: the perception of auditory and visual forms. **Bulletin of Mathematical Biophysics**, New York, v. 9, p. 127-147, 1947.

PETROVIC, A. M.; SIEBERT, J. E.; RIEKE, P. E. Soil bulk analysis in three-dimensions by computed tomographic scanning. **Journal / Soil Science Society of America**, Madison, n. 46, p. 445-450, 1982.

RUBIN, G. D.; SHIAU, M. C.; SCHMIDT, A. J.; FLEISCHMANN, D.; LOGAN, L.; LEUNG, A. N.; JEFFREY, R. B.; NAPEL, S. Computed tomographic angiography: historical perspective and new state-of-the-art using multi detector-row helical computed tomography. **Journal of computer assisted tomography**, New York, Nov. 23, suppl 1, p. S83-90, 1999.

SÄRKKÄ, S. Unscented Rauch-Tung-Striebel Smoother. **IEEE Transactions on Automatic Control**, New York, v. 53, n. 3, p. 845-849, 2008.

SIMONSEN, C. Self-adaptive model output statistics based on Kalman filtering. In: WMO TRAINING WORKSHOP ON THE INTERPRETATION OF NWP PRODUCTS IN TERMS OF LOCAL WEATHER PHENOMENA AND THEIR VERIFICATION, 1991, Wageningen, Holanda. **Lectures and Papers...** [S. l.: s. n.], 1991. p. XX-33-XX-37.

Comunicado Técnico, 100

Exemplares desta edição podem ser adquiridos na:

Embrapa Instrumentação Agropecuária
Rua XV de Novembro, 1542 - Caixa Postal 741
CEP 13560-970 - São Carlos-SP
Fone: 16 2107 2800 - **Fax:** 16 2107 2902
e-mail: sac@cnpdia.embrapa.br
<http://www.cnpdia.embrapa.br>

1a. edição

1a. impressão 2008: tiragem 300

Ministério da
Agricultura, Pecuária
e Abastecimento



Comitê de Publicações

Presidente: *Dr. Luiz Henrique Capparelli Mattoso*
Membros: *Dra. Débora Marcondes B. P. Milori,*
Dr. João de Mendonça Naime,
Dr. Washington Luiz de Barros Melo
Valéria de Fátima Cardoso

Membro Suplente: *Dr. Paulo S. P. Herrmann Junior*

Expediente

Supervisor editorial: *Dr. Victor Bertucci Neto*
Normalização bibliográfica: *Valéria de Fátima Cardoso*
Tratamento das ilustrações: *Valentim Monzane*
Editoração eletrônica: *Manoela Campos*