



## Utilização De Estatística de Ordem Superior para Remoção de Ruído em Perfis de Ressonância Magnética Nuclear em Poços de Hidrocarboneto

Paulo Roberto Alves Netto\* (PETROBRAS), Pedro Antonio Romero Rojas (Halliburton), e Giovanni Stael (Observatório Nacional)

Copyright 2015, SBGf - Sociedade Brasileira de Geofísica

This paper was prepared for presentation during the 14<sup>th</sup> International Congress of the Brazilian Geophysical Society held in Rio de Janeiro, Brazil, August 3-6, 2015.

Contents of this paper were reviewed by the Technical Committee of the 14<sup>th</sup> International Congress of the Brazilian Geophysical Society and do not necessarily represent any position of the SBGf, its officers or members. Electronic reproduction or storage of any part of this paper for commercial purposes without the written consent of the Brazilian Geophysical Society is prohibited.

### Abstract

The traditional procedure for increasing the signal-to-noise ratio of NMR echo trains is based on stacking and then averaging the data acquired at different depths up to a certain depth interval. Although this works efficiently in increasing the signal-to-noise ratio, it also reduces the vertical resolution of the acquired signal. Therefore a trade-off has to be made between cancelling the noise level without deteriorating the targeted signal but yet still achieving acceptable vertical and spectral resolutions. In NMR logging technology, vertical resolution, usually assessed by NMR-total porosity compared to neutron-density porosity, is important. However, noise can also affect the spectral distribution of the inverted signal that generates the  $T_1$  or  $T_2$  distribution and its components like: clay-bound water, irreducible water, and free fluid. In the area of machine learning applied to denoising, relatively new algorithm developments are using approaches like ICA (Independent Component Analysis), which are based on exploring the statistical independency of the signal components. ICA in fact, puts a stronger mathematical condition on the data-independency—rather than perpendicularity (which traditional Principal Component Analysis (PCA) is based on). However, since ICA is a kind of blind source separation algorithm, the subspace of the ICA solution is usually determined by the relevant numbers of principal components obtained after running PCA. There are several ICA approaches proposed in the literature. One of the most popular is the 'Fastlca' algorithm. We choose the Fastlca algorithm for our test due to its ease of implementation in the MATLAB computational environment. The results from simulated data show that ICA-denoising can be more effective than stacking, if the numbers of the blindly defined ICA components are properly selected. The tradeoff between preserving a significant amount of signal and filtering the right amount of noise is a sensitive aspect in implementing ICA for denoising when rock-fluid characteristics are being explored. Results from real data show that ICA can be readily adapted for post-processing in log analysis, but the selection of ICA-subspace poses a major challenge.

### Introdução

O fenômeno da ressonância foi observado pela primeira vez, por dois grupos de cientistas que trabalhavam de maneira independente nas universidades de Stanford, liderados por Felix Bloch, e Harvard, liderados por

Edward Mills Purcell. Ambos receberam o Nobel de Física pelos trabalhos pioneiros na área de Ressonância Magnética Nuclear (RMN) [1].

A Ressonância Magnética Nuclear (RMN) é encontrada em elementos que possuem momento magnético e angular não pareados. A informação obtida a partir das propriedades de RMN de rochas saturadas por fluidos é primeiramente baseada na relaxação do *spin* nuclear do Hidrogênio. Em RMN o núcleo magnético é estimulado, o qual absorve e reemite energia através de interações com outros núcleos. O sinal magnético associado com a reemissão desta energia tende a decair exponencialmente com constantes de tempo que são conhecidas como:  $T_1$ ,  $T_2$  e  $T_2^*$ . Onde  $T_1$  é a relaxação longitudinal,  $T_2$  é a relaxação transversal natural ou intrínseca do fluido e  $T_2^*$  é a relaxação transversal aparente, devido a não homogeneidade do campo magnético gerado [1].

A aplicação do método de RMN para estudar as propriedades petrofísicas de rochas na indústria do petróleo remonta a meados do século XX, tendo como pioneiro Russel Varian, que foi idealizador da primeira ferramenta de perfis de RMN. Por volta dos anos 60, ferramentas de perfil RMN, utilizando o campo magnético da terra, foram construídas com fins de exploração de petróleo. Entretanto, estas ferramentas não tiveram grande popularidade devido às suas limitações. Os resultados iniciais foram inesperados, constatou-se que efeitos de relaxação superficial da água no meio poroso eram significativos.

Apenas no início dos anos 90 foram introduzidas as ferramentas de RMN do tipo pulsado, que foram muito bem aceitas pela indústria de petróleo. Desde então, novas aplicações têm sido criadas, acompanhadas de melhoramentos das ferramentas [2].

Na tecnologia de perfilagem RMN, a resolução vertical, geralmente avaliada pela comparação entre as curvas de porosidade do RMN e as curvas de porosidade das ferramentas de perfil de densidade e neutrão, é importante. No entanto, o ruído também pode afetar a distribuição espectral do sinal invertido dos trens de eco da ferramenta de RMN que gera as distribuições de  $T_1$  e/ou  $T_2$  e seus componentes, como: água adsorvida em argilominerais, água irreduzível e fluido livre [3].

O procedimento tradicional para aumentar a relação sinal/ruído dos trens de eco da ferramenta de perfil a cabo de RMN baseia-se no empilhamento dos dados obtidos em diferentes profundidades. Embora este seja um método eficiente para aumentar a relação sinal-ruído, também reduz a resolução vertical do sinal adquirido. Portanto, é necessário estabelecer um equilíbrio entre cancelamento do ruído e manutenção da integridade do sinal adquirido, mas ainda assim alcançar resoluções verticais e espectrais aceitáveis.

Na área de aprendizagem automática aplicada à suavização, novos algoritmos têm sido desenvolvidos usando abordagens como ICA (*Independent Component Analysis*), que são baseados em explorar a independência estatística dos componentes do sinal [4].

ICA aplica uma condição matemática mais forte sobre a independência de dados, ao invés da perpendicularidade, sobre a qual a Análise de Componentes Principais (PCA) se baseia [4].

O método ICA busca encontrar uma representação linear onde os componentes sejam independentes e está estreitamente relacionado ao método chamado separação cega de fontes ou *Blind Source Separation* (BSS) [4, 5].

A ICA tem sido utilizada para processamento e análise de diversos tipos de dados, como o processamento para separação de artefatos em dados de Magnetoencefalografia (MEG), obtenção de fatores ocultos em dados do mercado financeiro, e para redução de ruído em imagens (naturais) [5].

Aplicações pioneiras de ICA para análise de dados de RMN foram realizadas por [6] para processar conjuntos de dados de Espectros de Ressonância Magnética (MRS), através da utilização do algoritmo FastICA [4, 5, 6].

Recentemente, [7] apresenta a aplicação e testes de diversos algoritmos de ICA para melhorar a deconvolução espectral de dados de Espectroscopia de RMN em alimentos e produtos relacionados. Nota-se a utilização desta ferramenta de análise em dados de RMN na área biomédica. Entretanto, a aplicação de ICA para tratamento e redução de ruído em dados de perfis de RMN ainda não havia sido explorada.

O ambiente de perfilagem a poço aberto é muito mais sujeito a fatores ambientais, como salinidade do fluido de perfuração, impurezas dentro poço, temperatura, entre outros, que a aquisição em laboratório. Estes fatores afetam diretamente a leitura do sinal de RMN. Sendo assim, a utilização pioneira de ICA para análise de tais dados, traz uma nova metodologia que pode ser adaptada para a redução do ruído e consequente melhora da resolução vertical, evitando-se o empilhamento, e espectral do dado adquirido, através da melhora do sinal adquirido.

Há várias abordagens de ICA propostas na literatura. Uma das mais populares é o algoritmo "FastICA". O mesmo foi escolhido para o teste, devido à sua facilidade de implementação no ambiente computacional MatLab.

### Princípios Básicos de RMN

O princípio físico básico da RMN conta com o fato de que o comportamento molecular de certos materiais pode ser afetado pela ação de um campo magnético.

Ressonância Magnética Nuclear é um fenômeno encontrado em sistemas de núcleos que possuem momentos magnético e angular [1, 3]. Na presença de um campo magnético externo ( $B_0$ ), o núcleo atômico apresenta precessão na direção do mesmo, ou seja, seus momentos magnéticos nucleares ( $\mu$ ) se alinham em

movimento de precessão ao redor desse campo, de maneira semelhante ao giroscópio que apresenta movimento de precessão alinhado ao campo gravitacional da Terra [3, 8].

Medidas de RMN podem ser realizadas em qualquer núcleo que apresente um número ímpar de prótons ou nêutrons ou ambos, como hidrogênio ( $^1\text{H}$ ), carbono ( $^{13}\text{C}$ ), e sódio ( $^{23}\text{Na}$ ). Para a maior parte dos núcleos atômicos encontrados em rochas sedimentares, o sinal magnético induzido por um campo externo é muito pequeno para ser detectado por uma ferramenta de perfilagem RMN a poço aberto. Entretanto, o  $^1\text{H}$  possui apenas um próton e nenhum nêutron, é abundante na composição dos fluidos (água, óleo e gás) presentes em rochas reservatório, possui um momento magnético relativamente grande, produzindo um "forte" sinal. Sendo assim, todas as medidas de ferramentas de perfilagem RMN são baseadas na resposta dos núcleos dos átomos de hidrogênio presentes nas formações sedimentares [3, 4, 9].

O primeiro passo na medição de RMN é o alinhamento do momento magnético do núcleo com campo magnético estático externo ( $B_0$ ). Quando  $B_0$  é aplicado ao momento magnético do núcleo,  $B_0$  exerce um torque no núcleo, que tende a alinhar seu momento angular (*spin*) em sua direção.

Quando um torque é aplicado a um objeto que possui momento angular, o eixo do objeto se move perpendicularmente ao torque em um movimento chamado de precessão. Dessa forma, quando  $B_0$  é aplicado ao momento magnético do núcleo, o núcleo realiza precessão ao redor de  $B_0$ . A frequência de precessão é chamada de frequência de Larmor [2, 3, 10].

Quando submetidos a um campo magnético de 550 Gauss, campo típico das ferramentas de perfilagem por RMN, os prótons dos fluidos de reservatório vão precessar com uma frequência de 2,3MHz. Este movimento de precessão perdura em equilíbrio até que o sistema seja perturbado por uma força externa [9].

A soma de todas as componentes longitudinais dos momentos magnéticos nucleares ( $\mu_z$ ) produz uma magnetização residual  $M_0$  que aponta para a mesma direção e sentido de  $B_0$ , num processo denominado de polarização [10]. No entanto, a resultante das componentes transversais ( $\mu_{xy}$ ), perpendiculares a  $B_0$ , é nula ( $M_{xy} = \sum \mu_{xy} = 0$ ). Esse fato deve-se à inexistência de coerência de fase entre elas [11], ou seja, embora possuam a mesma velocidade angular, estão distribuídas aleatoriamente no plano transversal (x-y) [8].

A magnetização resultante permanece nessa condição indefinidamente, até ser defletida por um pulso de radiofrequência  $B_1$ , aplicado perpendicularmente ao campo  $B_0$ . Aplicado sob a forma de pulsos de curta duração, da ordem de microssegundos, o campo magnético  $B_1$  exerce um torque sobre  $M_0$ , deslocando-a  $\alpha$  graus em relação ao eixo z. A magnetização longitudinal, antes alinhada na direção do eixo z, é projetada sobre o plano x'-y' gerando uma componente transversal não nula,  $M_{xy} \neq 0$  [9].

Ao término do pulso,  $M_0$  retorna ao seu alinhamento original num processo denominado relaxação magnética nuclear [10]. Durante esse processo, uma corrente elétrica amortecida, que constitui o sinal de RMN, é induzida numa bobina de detecção [12]. Tal sinal também é conhecido como decaimento livre de indução (FID - *Free Induction Decay*). A repetição desses pulsos em um determinado intervalo de tempo (sequência CPMG) dá origem ao que se denominam trens de ecos de RMN [1,9].

### Análise de Componentes Independentes (ICA)

Ao conjunto de dados de RMN foi aplicada a técnica de Análise de Componente Independente (ICA, em inglês). Trata-se de uma técnica para encontrar componentes, de um conjunto de dados multivariados (multidimensionais), que busca tais componentes utilizando a premissa de que são estatisticamente independentes e não gaussianos ao mesmo tempo [4].

O método ICA busca encontrar uma representação linear onde os componentes sejam estatisticamente independentes e está estreitamente relacionado ao método chamado separação cega de fontes ou Blind Source Separation (BSS) [5]. Onde "source" é entendido como o sinal original, componente independente, por exemplo, o sinal de RMN em meio poroso. "Blind" significa que se sabe muito pouco, ou nada, sobre uma matriz de mistura  $A$  e faz-se suposições frágeis sobre a fonte dos sinais. ICA é provavelmente o método mais utilizado para realização de BSS [4].

Para entender tal método, pode-se considerar que existam duas fontes de sinal  $s_1$  e  $s_2$ , a princípio sem nenhuma restrição quanto a sua natureza. Agora, considera-se que existam dois sensores. Desprezam-se aqui as diferenças de fase quanto aos sinais que chegam nestes sensores. Em cada sensor, irá chegar um sinal que será uma mistura de  $s_1$  e  $s_2$ . Essas misturas serão denominadas  $x_1$  e  $x_2$ . Contudo, para cada sensor a mistura se dará de forma diferente. O que irá diferenciar essas misturas será a proporção do sinal oriundo de cada fonte [13]. Essas misturas podem ser expressas como equações lineares:

$$x_1(t) = a_{11}s_1 + a_{12}s_2 \quad (1)$$

$$x_2(t) = a_{21}s_1 + a_{22}s_2 \quad (2)$$

Para definir-se ICA, pode-se utilizar um modelo estatístico de "variáveis latentes". Assume-se que são realizadas  $n$  observações de misturas lineares  $x_1, \dots, x_n$  de  $n$  componentes independentes, logo [4, 13]:

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n, \text{ para todo } j. \quad (3)$$

Assim, uma matriz de mistura  $A$  pode ser definida como:

$$\begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \end{bmatrix} \quad (4)$$

Trata-se do modelo mais simples de ICA [14] e pode ser representado na forma compacta, como:

$$x(t) = As(t) \quad (5)$$

Onde  $s(t) = [s_1(t), \dots, s_n(t)]^T$  representa os sinais da  $n$  fontes. Os  $n$  sinais observados são adquiridos para

formar  $x(t) = [x_1(t), \dots, x_n(t)]^T$ , que são os sinais que se encontram disponíveis.  $A$  representa a matriz de mistura  $n \times n$ .

Entretanto,  $A$  não é conhecida, caso fosse, bastaria resolver o sistema dado pela Eq. 4. Sendo assim, a recuperação das fontes  $s(t)$  deve ser feita a partir das  $n$  observações  $x(t)$ , assumindo que as fontes são: 1) estatisticamente independentes; 2) sua distribuição é não-gaussiana; 3) a matriz de mistura  $A$  é quadrada; e 4) possui inversa [11, 12, 14]. A recuperação das fontes  $s(t)$  só pode ser realizada através do cálculo iterativo da matriz de mistura  $W_{n \times n}$ , utilizando as  $x(t)$  observações disponíveis. Logo, as estimativas  $y(t)$  das fontes  $s(t)$ , são obtidas por:

$$y(t) = Wx(t) \quad (6)$$

Um dos princípios estatísticos para a escolha da matriz  $W$  (Eq. 4.7) é limitar o número de componentes  $y_i$  de maneira que  $W$  possa ser determinada e  $y_i$  mantenha tanta informação quanto seja possível. Isso leva a uma família de técnicas conhecida como análise de componentes principais (PCA, em inglês) [4].

Para estimar-se a matriz  $W$  (Eq. 6), algumas abordagens têm sido desenvolvidas, como os algoritmos FastICA [13], JADE e Akuzawa [14]. Essas abordagens vêm sendo aplicadas a vários tipos de dados. Nesse trabalho foi utilizada a abordagem proposta pelo algoritmo FastICA. Uma descrição resumida deste algoritmo será feita a seguir.

O algoritmo FastICA estima o vetor  $w(k)$ , sendo este uma das colunas da matriz ortogonal de mistura  $W$ . O algoritmo aplica PCA como uma forma de redução de dimensionalidade e branqueamento dos dados, tendo em vista, que o branqueamento é uma requisição do método.

Quando se quer estimar uma componente independente, pode-se utilizar a curtose, que é uma medida clássica de não-gaussianidade, então a derivação do algoritmo resulta na seguinte regra [15]:

1. Toma-se inicialmente um vetor aleatório  $w(0)$  de norma 1. Faz-se  $k = 1$ .
2. Faz-se  $w(k) = E\{x(w(k-1)^T x)^3\} - 3w(k-1)$ . A esperança pode ser estimada utilizando um grande número de vetores  $x$ .
3. Divide-se  $w(k)$  por sua norma.
4. Se  $|w(k)^T w(k-1)|$  não está próximo o suficiente de 1, faz-se  $k = k + 1$  e retorna ao passo 2. Caso contrário,  $w(k)$  é a solução.

O vetor final  $w(k)$ , dado pelo algoritmo, é igual a uma das colunas da matriz de mistura  $W$ . Na separação cega de fontes (BSS), isso significa que  $w(k)$  separa uma das fontes de sinal não-gaussiana, de maneira que  $w(k)^T x(t)$ ,  $t = 1, 2, \dots$  é igual a uma das fontes do sinal.

### Metodologia Aplicada aos dados de RMN

Foram utilizados para este trabalho os dados de perfil, a cabo, de RMN adquiridos em um poço portador de hidrocarbonetos. Ao todo, foram disponibilizados 60 m do

dado adquirido, gerando uma matriz de dados com 310 observações.

Aos dados, no domínio do trem de eco, foram aplicadas as técnicas de PCA para fins de compactação através de uma redução de dimensionalidade.

Após a redução de dimensionalidade os dados passam pela ICA. Realiza-se, então, uma análise de sensibilidade para encontrar o número ideal de componentes principais, que reduzam a dimensionalidade do dado guardando o máximo de informação, através da observação da mistura de sinais das fontes estimadas pela ICA.

Uma vez que seja encontrado o número ideal de PCA o dado filtrado através da ICA é o que será utilizado para obtenção do espectro de  $T_2$ .

Por fim, os dados filtrados foram carregados em um programa comercial de interpretação e processamento de perfis de poço, onde foram processados/invertidos juntamente com o mesmo dado não filtrado e empilhado com 3 níveis (prática comum na indústria) e comparados.

A figura 1 mostra as componentes independentes para a filtragem utilizando 4 componentes principais (PC's), após a análise de sensibilidade para a redução de dimensionalidade. Nota-se que existe sinal para todas as componentes independentes.

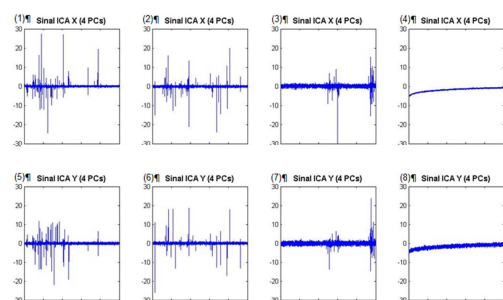


Figura 1: Matriz de mistura para as componente X e Y do campo magnético após a ICA com 4 PC's. Pode-se observar a existência de sinal até a quarta componente independente, tanto em X quanto em Y (eixo X: Trens de eco; eixo Y: Amplitude do sinal).

Após a análise da matriz de mistura segue-se a análise do dado filtrado versus o dado bruto. A sequência de figuras a seguir mostra de diferentes maneiras o dado filtrado e os efeitos da aplicação do método em relação ao dado bruto.

A figura 2 mostra os gráficos da componente X vs Y do campo magnético para os dados original e filtrado com 4 PC's. Nota-se o espalhamento do dado original sem empilhamento, essa aparente falta de coerência entre as componentes do campo magnético medido se deve ao ruído ambiental.

O dado filtrado com 4 PC's de entrada na ICA apresenta uma coerência bem razoável entre as componentes do campo magnético medido pela ferramenta. É possível, ainda assim, observar que o dado apresenta uma variância ao longo de um eixo de ajuste, mas ao se

comparar os dois gráficos, torna-se nítida a melhora da relação entre as componentes.




Figura 2: Comparação entre o dado filtrado com 4 PC's e original em relação as componentes do campo magnético.

A figura 3 mostra a comparação entre o dado original e filtrado com 4 PC's após a rotação.

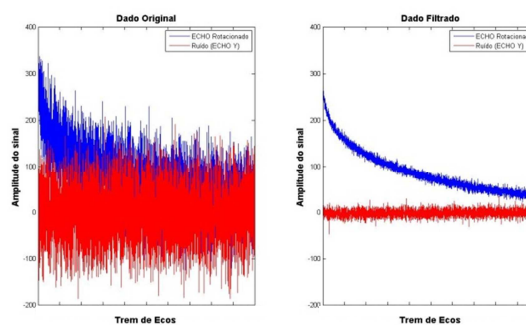


Figura 3: Gráfico com os trem de ecos da ferramenta de RMN original e filtrado com 4 PC's rotacionados.

É possível observar que os dados originais apresentam grande amplitude mesmo após o processo de rotação. Observa-se que o canal referente ao ruído ainda apresenta amplitudes comparáveis com o canal considerado sinal. O mesmo não ocorre com o dado filtrado com 4 PC's, onde é possível identificar uma clara separação entre o sinal e ruído pós rotação dos dados.

Para a comparação entre o dado filtrado e não filtrado foi utilizada a filtragem com 4 PC's, pois é o dado com o melhor custo computacional. Sendo assim, a figura 4 mostra a comparação entre os dados.

Observa-se o incremento na resolução espectral de  $T_2$  com a filtragem, é possível identificar que o ruído do dado está gerando uma resposta de microporosidade (tempos menores de  $T_2$ ) no dado não filtrado, empilhado ou não. A resposta de microporosidade, embora sempre apareça nesse tipo de dado, não era esperada para essa rocha em especial. Sendo assim, pode-se advogar que o ruído está gerando essa resposta de microporosidade. Outra observação interessante se refere ao dado que passou pelo processo de empilhamento, onde o processo não foi eficaz em remover o sinal da microporosidade, apenas suavizou o dado diminuindo sua resolução vertical.

## Figuras

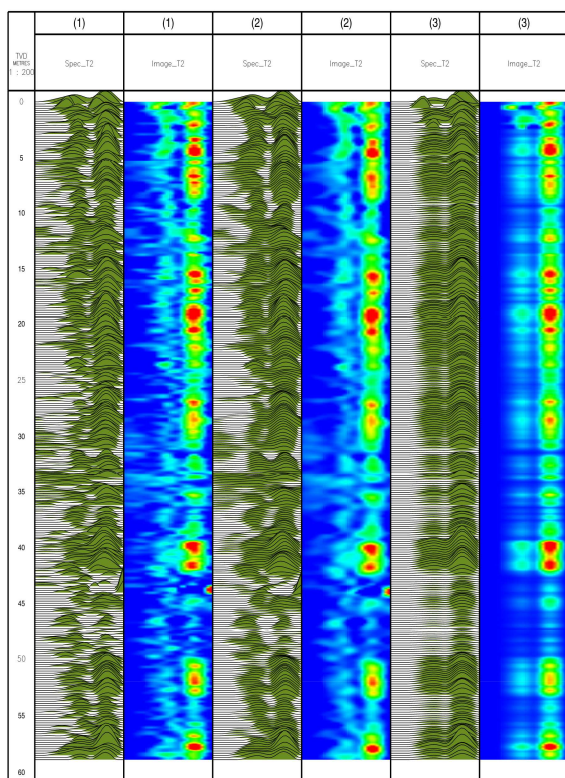


Figura 4: Comparação entre: (1) inversão do dado sem filtragem e sem empilhamento; (2) inversão do dado sem filtragem com empilhamento de três níveis para cima; (3) inversão do dado filtrado após remoção de ruído através da Análise de Componentes Independentes (ICA) com 4 PC's.

A figura 5 mostra a comparação entre os dados. Pode-se observar que a variância do dado filtrado com 4 PC's segue, de maneira geral a tendência do dado não filtrado, principalmente onde este apresenta a maior variância. Na trilha 3 observa-se que a porosidade total (PHIT) não apresenta grandes variações em relação ao dado não filtrado, entretanto mostra um incremento de até 5% de porosidade em relação ao dado não filtrado em determinados intervalos, já em outros intervalos apresenta porosidades um pouco menores.

A porosidade efetiva (PHIE), na trilha 4, apresenta a mesma tendência em relação ao dado não filtrado que a observada para a PHIT. Cabe observar, que nas áreas onde o espectro de  $T_2$  do dado não filtrado apresenta a maior variação e indicação de microporosidade o dado filtrado não apresenta tal porosidade, refletindo valores de PHIT e PHIE menores que os valores calculados a partir do dado não filtrado. Sugere-se, então, que o ruído nessas áreas é o gerador de uma microporosidade fictícia, que é corrigida pelo processo de filtragem. Como informação adicional, não é esperado para essa área um conteúdo de microporosidade suficiente para ser detectado pela ferramenta de RMN, quando são verificados os dados de amostras de rocha do intervalo estudado.

Na trilha 5 pode ser observado que a porosidade fluido livre (FF) praticamente não se altera, apresentando, assim, uma melhor resolução vertical em relação ao dado empilhado.

Outra mudança significativa ocorre na média geométrica do espectro de  $T_2$  (T2LM), trilha 6, pois, tendo em vista, que a filtragem melhorou a resolução espectral do dado, observa-se um comportamento mais suave da curva em relação ao dado não filtrado e ao dado empilhado.

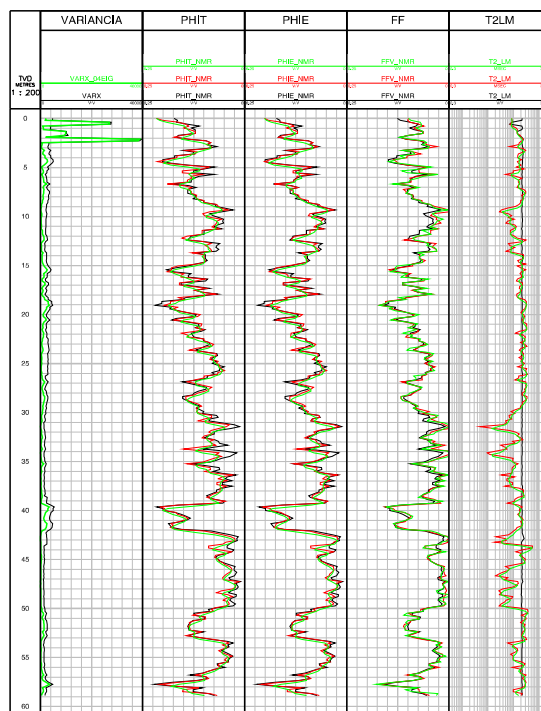


Figura 5: Gráfico mostrando a comparação entre o dado filtrado com 4 PC's (preto), não filtrado (vermelho) e empilhado com 3 níveis (verde). Na trilha 1 é mostrada a profundidade, trilha 2 observa-se a variância do dado filtrado (verde) e a variância do dado não filtrado (preto). Na trilha 3 observa-se a porosidade total (PHIT), na trilha 4 a porosidade efetiva (PHIE), na trilha 5 a porosidade fluido livre (FF) e na trilha 6 a média logarítmica do espectro de  $T_2$  (T2LM).

## Conclusão

Foi desenvolvida uma nova técnica de filtragem de dados de RMN a partir da utilização da ICA. O conjunto de dados de perfil de uma ferramenta de RMN disponível foi submetido ao processo de filtragem apresentando bons resultados em relação ao tratamento convencional.

No intuito de encontrar o número de PC's ideal, foram realizados vários ciclos de filtragem com diferentes números de componentes principais, consistindo esse processo em uma análise de sensibilidade onde o objetivo principal foi o estabelecimento de uma rotina de validação do processo de filtragem.

Após a comparação entre todas as filtragens optou-se pela realizada com 4PC's, pois é possível observar-se que a tendência da variância da componente X é

respeitada. Sendo assim, na fase de inversão foi adotada a filtragem com 4 PC's para a comparação entre os dados, por ser a que apresenta o melhor resultado, ou seja, retém o máximo de informação após a filtragem de ruído, utilizando a dimensão mínima possível dos dados adquiridos.

A comparação entre o dado filtrado com 4 PC's, o dado não filtrado e o dado não filtrado com empilhamento de 3 níveis para cima foi realizada e pôde-se observar o incremento na resolução espectral de  $T_2$  com a filtragem.

Finalmente, a comparação entre os dados mostrou que além da melhora na resolução espectral, houve um incremento de até 5% nas porosidades total e efetiva em determinados intervalos, principalmente onde a variância do dado não filtrado é maior. Em outros intervalos tais porosidades ficaram cerca de 2% abaixo das porosidades calculadas com o dado não filtrado, principalmente em áreas onde o espectro de  $T_2$  mostrava sinal nos tempos curtos, sugerindo que o ruído nessas áreas é o gerador de uma microporosidade fictícia, que foi corrigida pelo processo de filtragem. Uma futura comparação com a porosidade de amostras de rocha pode mostrar quão eficiente é o processo.

Outra mudança significativa ocorreu na média geométrica do espectro de  $T_2$  (T2LM), pois, tendo em vista, que a filtragem melhorou a resolução espectral do dado, observou-se um comportamento mais suave da curva em relação ao dado não filtrado e ao dado empilhado.

Conclui-se assim, que a metodologia criada e aplicada ao conjunto de dados disponíveis foi eficiente na filtragem do ruído, trazendo informação pertinente ao conhecimento científico, além de resultados práticos à caracterização de reservatórios de hidrocarbonetos e avaliação de formações.

#### Agradecimentos

Os autores agradecem à Petrobras S.A. pelo suporte e autorização para utilização e divulgação dos dados.

#### Referências

- [1] DUNN, K.-J., BERGMAN, D.J., LATORRACA, G.A, Nuclear Magnetic Resonance Petrophysical and Logging Applications (Handbook of Geophysical Exploration. Seismic Exploration Vol. 32), Amsterdam, Pergamon, 293 p., 2002.
- [2] ELLIS, V. D., SINGER, J.M., Well Logging for Earth Scientists, 2a Edição, Holanda, Springer, 692 p., 2008.
- [3] COATES, G.R., XIAO,L., MANFRED, G.P, NMR Logging: Principles and Applications, Houston, Gulf Professional Publishing, 234 p., 1999.
- [4] HYVÄRINEN, A., KARHUNEN, J., OJA, E. Independent Component Analysis. John Wiley & Sons, 481 p., 2001.
- [5] HYVÄRINEN, A., OJA, E. Independent Component Analysis: Algorithms and Applications. Neural Networks, Vol. 13(4-5): pp. 411-430, 2000.
- [6] MA, J., SUN, Z. Q. Exploring the Intrinsic Structure of Magnetic Resonance Spectra Tumor Data Based on Independent Component Analysis and Correlation Analysis, in Artificial Neural Networks - ICANN 2006, PT 2 (Eds: S. Kollias, A. Stafylopatis, W. Duch, E. Oja), Springer, Berlin-Heidelberg, 2006, 788–797.
- [7] MONAKHOVA, Y.B., TSIKIN, A. M., KUBALLA, T., LACHENMEIER, D. W., MUSHTAKOVA, S. P. Independent Component Analysis (ICA) Algorithms for Improved Spectral Deconvolution of Overlapped Signals in  $^1\text{H}$  NMR Analysis: Application to foods and related products. Magnetic Resonance in Chemistry, Vol. 52(5): pp. 231-240., 2014.
- [8] RIOS, E.H., Caracterização Petrofísica de Rochas Reservatório por RMN: Abordagem Clássica e Modelos Multivariados. Dissertação de M.Sc., Geofísica/Observatório Nacional, Rio de Janeiro, RJ, Brasil, 2011.
- [9] MACHADO, V.F., Inteligência Computacional na Estimativa da Permeabilidade e de Reservatórios de Petróleo a Partir de Perfis de RMN. Dissertação de M.Sc., Engenharia Civil/UFRJ, Rio de Janeiro, RJ, Brasil, 2010.
- [10] GIL, V.M.S., GERALDES, C.F.G.C., Ressonância Magnética Nuclear: Fundamentos, Métodos e Aplicações. Lisboa, Fundação Calouste, pp. 3-710, 1987.
- [11] CALLAGHAN, P.L., Principles of Nuclear Magnetic Resonance Microscopy. New York, Oxford University Press Inc., 1993.
- [12] BLUMICH, B., Essential NMR for scientists and engineers, 1 ed., Berlin, Springer, 2005.
- [13] DINIZ, F.C.C.B., Supressão de Ruído, Detecção e Classificação de Sinais de Descargas Parciais em Transformadores de Potência. Dissertação de M.Sc. Engenharia Elétrica, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2005.
- [14] RAMOS, R.R., Redes Neurais para Monitoração de Estacionariedade de Sinais de Sonar Passivo. Dissertação de M.Sc. Engenharia Elétrica, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2011.
- [15] HYVÄRINEN, A., OJA, E., A Fast Fixed-Point Algorithm for Independent Component Analysis. In: Neural Computation, v. 9, pp. 1483-1492, 1997.