

Integração de dados para a classificação de eletrofácies por mapas auto-organizáveis

Data integration for electrofacies classification using self-organizing maps

Michelle Chaves Kuroda | Alexandre Campana Vidal | Juliana Finoto Bueno | Bruno César Zanardo Honório | Emilson Pereira Leite | Rodrigo Duarte Drummond

resumo

A fim de minimizar as incertezas intrínsecas à classificação litológica de eletrofácies a partir de perfis, são descritas nove estratégias de classificação por redes neurais não supervisionadas, mapas auto-organizáveis (*self-organizing maps* - SOM), que combinam informações de perfis geofísicos com dados provenientes de derivadas dos perfis, expoentes de Hölder e impedância acústica. O método é aplicado a um reservatório carbonático do Albiano, da Bacia de Campos, para o qual foram utilizados os perfis sônico (*DT*), porosidade neutrônica (*NPHI*), densidade (*RHOB*) e raios gama (*GR*). Mediante a escassez de dados de testemunhos, as classificações foram realizadas em duas etapas: inicialmente foi feita a classificação do conjunto de perfis geofísicos e impedância acústica,

que em uma segunda etapa foi utilizada como variável adicional em testes com o algoritmo na busca pela classificação de dados de testemunho que descrevem quatro fácies (reservatório, possível reservatório, não reservatório e cimento). Dentre os cenários analisados, os melhores resultados estão associados à inserção de informações de impedância acústica e desta nova variável. Adicionadas à suíte básica de perfis geofísicos no conjunto de treinamento do SOM, obteve-se um aumento de acerto da classificação de dados de testemunho de 16%. Os resultados possibilitam quantificar a potencialidade da integração de dados sísmicos na classificação automática de dados de poços pelo método de SOM.

Palavras-chave: mapas auto-organizáveis | classificação de eletrofácies | impedância acústica | expoentes de Hölder

abstract

In order to minimize uncertainties inherent to electrofacies classification from well log data, this paper describes nine different strategies for classification using unsupervised neural networks, self-organizing maps (SOM), which combine geophysical information with data derived from well logs, Hölder exponent and acoustic impedance. The method was applied to the Albian carbonate reservoir of the Campos Basin, for which the following well logs were used: sonic (DT), neutron porosity (NPHI), density (RHOB) and gamma ray (GR). Due to the scarcity of core data, the classifications were performed in two steps: first, the classification of well logs and acoustic impedance were performed, which were then used as an additional variable in tests with the algorithm seeking to classify the core data that describe four core data facies (reservoir, possible-reservoir, non-reservoir and cement). The best results of the analysis are associated with the insertion of acoustic impedance information and of such new variable. Adding the new variable to well log samples in the training dataset resulted in a 16% increase in accuracy in core data classification. The results allow the potential integration of seismic data to be quantified in the automatic classification of well data by the SOM method.

(Expanded abstract available at the end of the paper).

Keywords: self-organizing maps | electrofacies classification | acoustic impedance | Hölder exponent

introdução

Uma das etapas iniciais da caracterização de reservatórios é a classificação de fácies presentes no campo, com base em dados de poços e de levantamentos sísmicos. Com isso, a aplicação de estratégias eficientes de classificação de fácies constitui uma etapa fundamental da caracterização e modelagem do reservatório (Arzuman, 2009; Bhatt e Helle, 2002; Drummond e Vidal, 2011; Yang *et al.*, 2004).

A grande heterogeneidade geológica e petrofísica dos reservatórios carbonáticos requer o desenvolvimento de técnicas de análise multivariada que integrem informações e aumentem a capacidade computacional de reconhecimento de padrões faciológicos (Bhatt e Helle, 2002; Stundner e Oberwinkler, 2004; Esposito *et al.*, 2008).

Com tal objetivo, este trabalho demonstra a aplicação da rede neural não supervisionada, mapas auto-organizáveis (*self-organizing maps* - SOM) em um reservatório carbonático do Albiano da Bacia de Campos, denominado Reservatório A.

O método de rede neural desenvolvido por Kohonen (2001) é inspirado no funcionamento do cérebro humano e utilizado para reconhecimento, classificação e generalização de padrões. As redes neurais são guiadas pelos dados e durante seu treinamento são capazes de se adaptar e desenvolver associações multivariadas e não lineares (Haykin, 2001; Kohonen, 2001; Leite e Souza Filho, 2010; Matos *et al.*, 2007; Meldahl *et al.*, 2001).

Coléou *et al.* (2003) defendem o uso de SOM por apresentar resultados mais precisos em detrimento de outras técnicas estatísticas multivariadas, como *principal component analysis* (PCA), *independent component analysis* (ICA) e *k-Means* (k-Médias), utilizando critérios de comparação como redundância, ruído e continuidade.

O método apresenta extensa aplicação nas áreas de geologia e geofísica de reservatórios. Poulton (2001) ilustra possíveis contribuições para o processamento e interpretação sísmica (reconhecimento de padrões de ondas, identificação de horizontes, edição de traços, análise de velocidade, eliminação de múltiplas, deconvolução, inversão e atenuação de ruído) e caracterização de reservatórios (mapeamento de fácies, predição de propriedades petrofísicas e caracterização de litologias).

Diferentes trabalhos demonstram a viabilidade do método para classificação de eletrofácies (Bhatt e Helle,

2002; Saggaf e Nebrija, 2000; Stundner e Oberwinkler, 2004), como o trabalho de Kuroda *et al.* (2012), que aplicam o método de SOM para caracterização de rochas siliciclásticas do Campo de Namorado.

No estudo de rochas carbonáticas, Yang *et al.* (2004) e Saggaf e Nebrija (2000) utilizam diferentes aplicações da rede neural supervisionada de Retropropagação de Erros para a classificação de litotipos, com resultados superiores a 90% de acerto.

Entretanto, a classificação de eletrofácies realizada apenas com perfis geofísicos (*RHOB*, *DT*, *GR* e *NPHI*) e pouca quantidade de informação para validação do método pode resultar em baixos valores de acerto.

A fim de melhorar o desempenho do algoritmo SOM, diferentes estratégias de classificação precisam ser testadas. Com este propósito, diversas informações foram adicionadas a fim de buscar a melhor determinação de fácies, como as derivadas dos perfis e os expoentes de Hölder, além de informações advindas de dados sísmicos através da impedância acústica (*AI*).

O expoente de Hölder busca caracterizar as singularidades presentes em um sinal. Sua utilização na classificação litológica se baseia no fato de perfis geofísicos apresentarem respostas significativamente diferentes para litologias distintas (Álvarez *et al.*, 2003).

A impedância acústica, obtida através de métodos de inversão, busca eliminar ambiguidades da reflexão sísmica a partir da incorporação de informações e princípios petrofísicos na interpretação sísmica, transformando as amplitudes em propriedades elásticas e acrescentando informações que não podem ser extraídas da interpretação sísmica convencional (Tarantola e Valette, 1982; Avseth *et al.*, 2008; Eastley *et al.*, 2012).

Neste contexto, a técnica de inversão do dado sísmico em impedância acústica tem se mostrado um excelente método na integração de dados de perfis geofísicos e sísmicos (Sancevero *et al.*, 2006). A vantagem deste tipo de inversão deve-se ao fato da impedância estar associada a propriedades das rochas (litologia, porosidade, permeabilidade, entre outras) e não a uma interface, como acontece na amplitude do dado sísmico original. Esta característica transforma o modelo de contrastes sísmicos em um modelo de camadas, facilitando a interpretação do significado geológico e petrofísico dos limites dos corpos sísmicos em subsuperfície (Tarantola e Valette, 1982; Avseth *et al.*, 2008).

Além das variáveis descritas, o método de SOM foi aplicado em uma etapa anterior para a geração de uma nova variável, a qual foi inserida no conjunto de treinamento para classificação de eletrofácies. Com o método sendo aplicado em mais de uma etapa, os resultados são

refinados, aumentando a taxa de acerto da classificação de eletrofácies do Reservatório A.

métodos

som

Os mapas auto-organizáveis (*self-organizing maps* - SOM) são uma técnica de redes neurais que não utiliza informações a priori do conjunto de dados para classificação (Kohonen, 2001). Esta característica os torna adaptáveis a diferentes tipos de dados e um auxiliar na caracterização geofísica de dados com ausência ou escassez de identificação geológica (Arzuman, 2009; Bhatt e Helle, 2002).

O algoritmo é constituído por duas camadas: a camada de entrada, composta pelos dados geofísicos a serem analisados, e a camada de saída, representada por uma malha elástica formada por unidades computacionais interligadas, chamadas de nós ou neurônios (Kohonen, 2001). Cada neurônio representa um padrão sísmico diferente e, quanto maior a distância entre os nós, maior a diferença de padrões que representam devido à preservação topológica do algoritmo.

Na camada de entrada, cada amostra analisada representa um vetor linha: $x = [x_1, x_2, \dots, x_n] \in R_n$ conectada aos neurônios da camada de saída. Os neurônios, por sua vez, estão associados a vetores de pesos sinápticos individuais $m_i = [m_{i1}, m_{i2}, \dots, m_{in}]^T$, para $i = 1, 2, \dots, nu$, em que nu é o número de neurônios da segunda camada. Tais pesos são responsáveis pelo ajuste dos neurônios da camada de saída, que se aproximam estatisticamente das amostras com maior similaridade, preservando a estrutura topológica da rede (Kohonen, 2001).

O algoritmo se baseia em um processo de aprendizagem competitiva no qual apenas o neurônio mais similar fornece uma resposta ativa a um sinal de entrada corrente. Este neurônio é chamado de *best matching unit* (BMU), e a medida de similaridade entre os neurônios e cada uma das amostras é calculada a partir da distância euclidiana (Kohonen, 2001), segundo mostra a equação 1:

$$\begin{cases} m_i = m_i(t) + \alpha(t)h_{bi}(t)[x - m_i(t)], & \text{se } m_i \in \\ & \text{vizinhança de } c \text{ caso contrário.} \\ m_i = m_i, \end{cases} \quad (1)$$

Onde:

t = tempo;

$\alpha(t)$ = taxa de aprendizado, responsável pela intensidade da atração do vetor de entrada.

Esta taxa varia de 0 a 1 (e decresce ao longo das iterações até que ocorra convergência) segundo a equação 2:

$$\alpha(t) = \frac{\alpha_0}{1 + 100 \frac{1}{T}}, \quad (2)$$

Onde:

T = número total de iterações;

α_0 = razão de aprendizado inicial.

A vizinhança que é atualizada a cada iteração é definida por $h_{bi}(t)$, descrito pela equação 3:

$$h_{bi}(t) = e^{-\frac{|r_b - r_i|}{2\sigma^2(t)}}, \quad (3)$$

Onde:

r_b e r_i = posições dos neurônios b e i no reticulado do SOM.

Desta forma, o algoritmo preserva as relações topográficas dos dados de entrada no arranjo SOM, cuja qualidade de agrupamento pode ser analisada segundo erro de quantização (qe) associado à resolução do SOM e erro topográfico (te) associado à preservação de topologia dos dados de entrada, definidas respectivamente por:

$$qe = \frac{1}{M} \sum_{k=1}^M \|x_k - m_{bk}\| \quad e \quad te = \frac{1}{M} \sum_{k=1}^M f(x_k) \quad (4)$$

em que M é a quantidade de vetores x , e a função $f(x_k)$ é igual a 1 se a primeira e a segunda BMUs de x_k são adjacentes e 0 (zero), caso contrário.

Para visualização dos agrupamentos, utiliza-se a matriz-U, que é a matriz unificada de distâncias entre os neurônios do arranjo SOM, no qual cada elemento representa o valor médio dos pesos dos neurônios adjacentes e a distância entre eles. Assim, para um arranjo SOM com $nu = nx \times ny$ elementos, em que nx e ny são calculados pela relação heurística de Vesanto *et al.* (2000) $nu = 5 \times \sqrt{M}$, a matriz-U será composta por $3 \times nx \times ny - nx - ny$ elementos.

Em geral, nu é um valor muito alto e necessita de um segundo reagrupamento. Com este propósito foi utilizado o método *k-Means* (Khedairia e Khadir, 2008), desenvolvido por MacQueen em 1967, para o qual o número de grupos (k) é definido pelo índice Davies-Bouldin (Davies e Bouldin, 1979).

Depois do treinamento, os dados são separados em k grupos. Entretanto, como o algoritmo não é supervisionado, os grupos encontrados podem ser interpretados com a análise de especialistas, por aplicação de valores médios das variáveis ou ainda utilizando informações de classificação, caso sejam disponibilizadas (Kohonen, 2001).

O método de SOM foi aplicado em duas etapas, a primeira para a classificação dos dados de perfis e impedância, que foi utilizada como variável adicional na segunda aplicação do SOM, resultando na determinação final das eletrofácies. O controle aproximado sobre os resultados da primeira classificação foi definido ao se escolherem seis agrupamentos para a classificação, número semelhante de tipos litológicos descritos na amostra de calha. Com isso foi possível inferir as prováveis litologias classificadas.

Na segunda utilização do método de SOM, foram processadas várias possibilidades de configuração entre as variáveis, e a escolha para a quantificação da taxa de acerto foi obtida com a correlação das informações de testemunho.

Por fim, os dados com informações de calha e/ou testemunho foram contabilizados, e a classe com maior amostragem foi escolhida como sendo o rótulo do grupo.

Dessa forma, os dados-alvo (de calha ou testemunho) não são utilizados para treinamento do algoritmo SOM. Entretanto, tais informações são empregadas para identificação posterior dos grupos encontrados, possibilitando a quantificação do desempenho do algoritmo.

expoentes de Hölder

Com o objetivo de extrair mais informações dos perfis de poço que pudessem auxiliar na classificação de fácies, foi adotado um procedimento para caracterizar as singularidades dos mesmos. Para isso, utilizou-se a transformada *wavelet* contínua (*continuous wavelet transform* - CWT), que foi primeiramente formalizada por Grossman e Morlet (1984). Ela é definida como a correlação cruzada entre o sinal analisado e versões dilatadas da função

wavelet base. A CWT pode ser interpretada como a convolução entre o sinal e a *wavelet* em diferentes escalas (*wavelets* filhas).

A representação da CWT de um sinal unidimensional se dá no plano tempo-frequência, também chamado de escalograma. Cada coeficiente da matriz que compõe esse plano representa o quão bem o sinal se correlaciona com cada uma das *wavelets* filhas num dado instante de tempo (ou profundidade).

Mallat e Zhong (1992) mostraram como as linhas de máximo módulo ao longo das escalas da CWT (*wavelet transform modulus maxima line* - WTMM) podem ser utilizadas para detectar bordas ou transições de um sinal. Tu e Hwang (2005) estenderam esse conceito para *wavelets* complexas.

Diversos trabalhos no contexto da geofísica utilizam essa propriedade derivada da CWT para extrair informações adicionais do sinal avaliado (Herrmann e Stark, 2000; Lyons *et al.*, 2001; Li e Liner, 2005; Matos *et al.*, 2007). Estes trabalhos avaliaram o comportamento da WTMM e determinaram o quão forte são as transições do sinal. Matematicamente, transições são chamadas de singularidades e podem ser caracterizadas através dos expoentes de Lipschitz ou expoentes de Hölder (Mallat e Hwang, 1992).

A obtenção do expoente de Lipschitz/Hölder α através da evolução dos máximos do módulo da transformada *wavelet* pode ser derivada do seguinte teorema (Mallat, 1998):

Teorema: Se $f \in L^2(\mathcal{R})$ e é uniformemente Lipschitz $\alpha \leq n$ em um intervalo $[a, b]$, então existe um valor $A > 0$ tal que:

$$\forall (u, s) \in [a, b] \times \mathcal{R}^+, \quad |Wf(u, s)| \leq As^{\alpha + \frac{1}{2}} \quad (5)$$

Onde:

$Wf(u, s)$ = a transformada *wavelet* do sinal f com os parâmetros de escala e deslocamentos dados por s e u , respectivamente.

Inversamente, se $Wf(u, s)$ satisfizer a equação 5 e se $\alpha \leq n$ não for um número inteiro, então f é uniformemente α Lipschitz no intervalo $[a + \varepsilon, a - \varepsilon]$, para qualquer $\varepsilon > 0$.

Aplicando o logaritmo em base 2 na equação 5, temos:

$$\log_2 |Wf(u, s)| \leq \log_2 A + \left(\alpha + \frac{1}{2} \right) \log_2 S \quad (6)$$

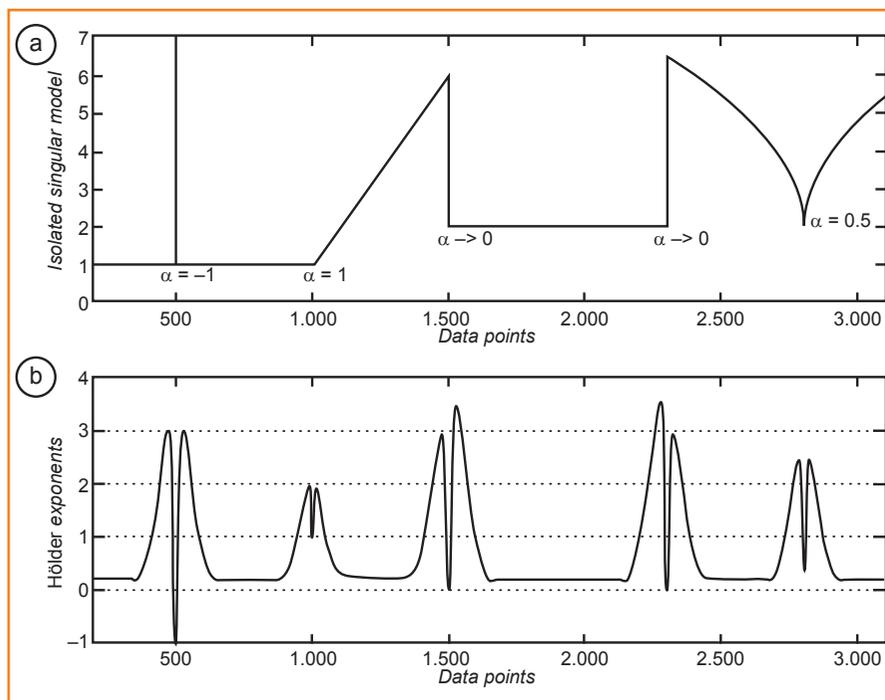


Figura 1

a. Modelo com cinco pontos singulares; b. Expoentes de Hölder calculados utilizando a CWT (Modificado de Li e Liner, 2008).

Figure 1

a. Model with five singular points; b. Hölder exponents calculated using CWT (Modified from Li and Liner, 2008).

Alguns autores demonstraram que a WTMM tende a ser linear diretamente acima dos pontos singulares (Seuret e Gilbert, 2000; Li, 2002; Li e Liner, 2008). Portanto, o esforço em procurar pela WTMM pode ser eliminado, de modo que o cálculo do expoente de Hölder se torna muito mais simples e rápido. A figura 1 representa um modelo com pontos singulares isolados com expoentes de Hölder variando de -1 a 1.

Percebe-se que em torno dos pontos singulares ocorre uma espécie de artefato dentro do cone de influência da CWT. No entanto, os autores defendem que tais artefatos são suprimidos quando os pontos singulares ocorrem próximos, como no caso da impedância acústica e no traço sísmico no qual cada ponto pode ser considerado um ponto singular (Li e Liner, 2005). Estendendo esse conceito para perfis geofísicos, os expoentes de Hölder podem ser calculados em cada amostra do sinal.

Assim, para o cálculo dos expoentes de Hölder, basta obter os coeficientes da CWT e traçá-los contra o parâmetro escala, ambos em logaritmo base 2. O expoente de Hölder, portanto, será diretamente proporcional (a menos de uma constante) à inclinação da reta que melhor se ajusta aos pontos da curva. A figura 2 ilustra a obtenção dos expoentes de Hölder para o perfil sísmico (DT).

De maneira análoga, os expoentes de Hölder podem ser obtidos para cada um dos perfis geofísicos, gerando-se assim novos perfis, os quais podem

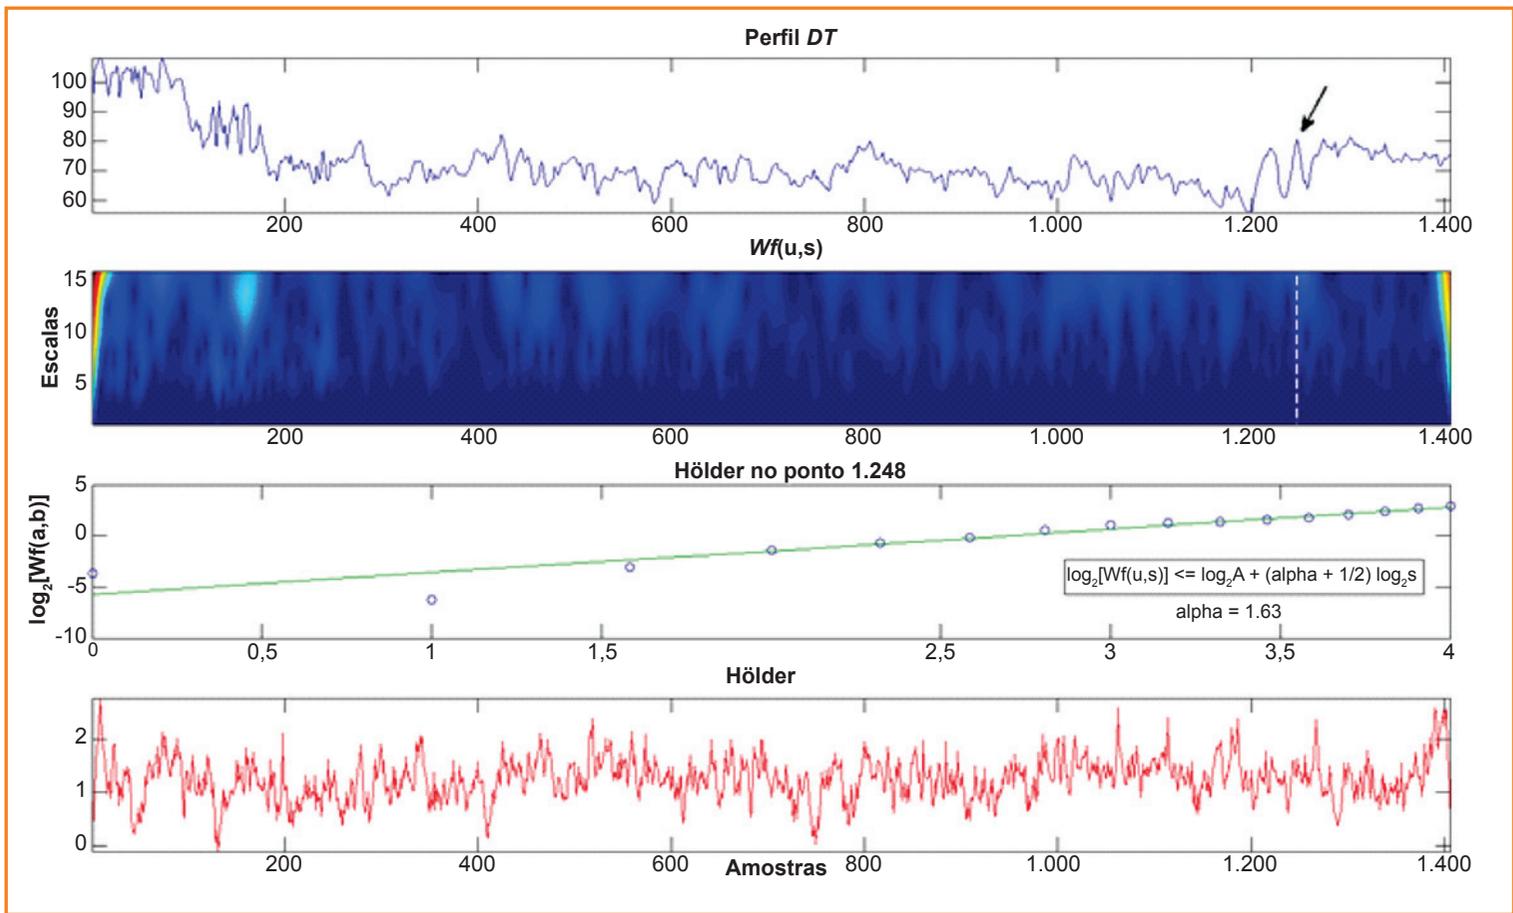


Figura 2
Exemplo da obtenção dos expoentes de Hölder para o perfil sônico (DT) (Modificado de Li e Liner, 2008).

Figure 2
Example of how Hölder exponents were obtained for sonic logs (DT). CWT (Modified from Li and Liner, 2008).

ser inseridos como informação adicional no processo de classificação litológica.

impedância acústica (IA)

A impedância acústica (IA) foi determinada por um método de inversão sísmica determinística (Russel, 1988), a partir da qual pode ser sintetizada, pela equação 7, uma fórmula prática utilizada na inversão recursiva para a transformação da refletividade em impedância. Em que IA_1 é a impedância acústica conhecida no topo da camada e IA_M é a na M-ésima camada. O r_j é o coeficiente de reflexão da j-ésima camada. Esta aproximação é válida para a maioria dos casos práticos onde $r_j \leq |0.3|$ (Oldenburg et al., 1983; Berteussen e Ursin, 1983).

$$IA_M = IA_1 \exp\left(2 \sum_{j=2}^M r_j\right) \quad (7)$$

Na prática, os valores de IA na posição de cada amostra sísmica podem ser extraídos de um modelo

3D cobrindo o volume sísmico inteiro, calculados através da krigagem ordinária dos valores conhecidos de IA na posição dos perfis de poço. Para a correta utilização da inversão recursiva, os traços sísmicos devem ser deconvolvidos em séries de refletividade como sugerido pela equação 7. Para a realização disto, foi aplicado um procedimento de otimização *constrained sparse-spike* que minimiza a função objetivo, utilizando o algoritmo de gradiente-conjugado (Oldenburg et al., 1983, Berteussen e Ursin, 1983).

$$J(r) = \alpha \frac{1}{p} \sum_{j=1}^M |r_j|^p + \frac{1}{2} \left\| \frac{1}{\sigma} (s - Wr) \right\|^2 + \frac{1}{2} \left\| C^{-1} (z - Hr) \right\|^2, \quad (8)$$

O primeiro termo na equação 8 é providenciado para permitir a minimização do L_1 – norma das refletividades, onde α controla a esparsidade da solução. Com o segundo termo, o algoritmo também minimiza a diferença entre o traço sísmico sintético (Wr) e o traço observado (s). W é a matriz de coeficientes da *wavelet* e σ é o desvio padrão dos ruídos no dado

sísmico. Outros algoritmos de otimização também podem ser utilizados para minimizar a equação 8, como o algoritmo *iterative reweighted least squares* (Björck, 1996) ou o algoritmo *soft-thresholding* (Loubes e De Geer, 2002). Após a estimativa de r dos dados de amplitudes sísmicas, ele é então invertido em IA .

análise de dados

Neste trabalho foram analisados 26 poços do Reservatório A (fig. 3), para os quais foram disponibilizados os perfis sônico (DT), porosidade neutrônica ($NPHI$), densidade ($RHOB$) e raios gama (GR). Para a obtenção da impedância acústica foi utilizado o volume de amplitude sísmica (fig. 3).

Dezesseis dos 26 poços analisados possuem informações de dados de calha, com seis litologias: arenito, calcilutito, calcissilito, calcarenito, marga e folhelho. Para a análise dos dados de testemunho a densidade de informações provenientes de dois poços tornou necessário o agrupamento da descrição de fácies em quatro classes: reservatório (*grainstone*), possível reservatório (*packstone*), não reservatório (*wackstone*, *floatstone*, brecha carbonática, margas e *mudstone*) e cimento (todas as fácies descritas como cimentadas).

cenários

Os perfis DT , GR , $NPHI$ e $RHOB$ foram utilizados como suite básica em todos os treinamentos do método de SOM. As informações de profundidade dos poços também foram adicionadas à suite

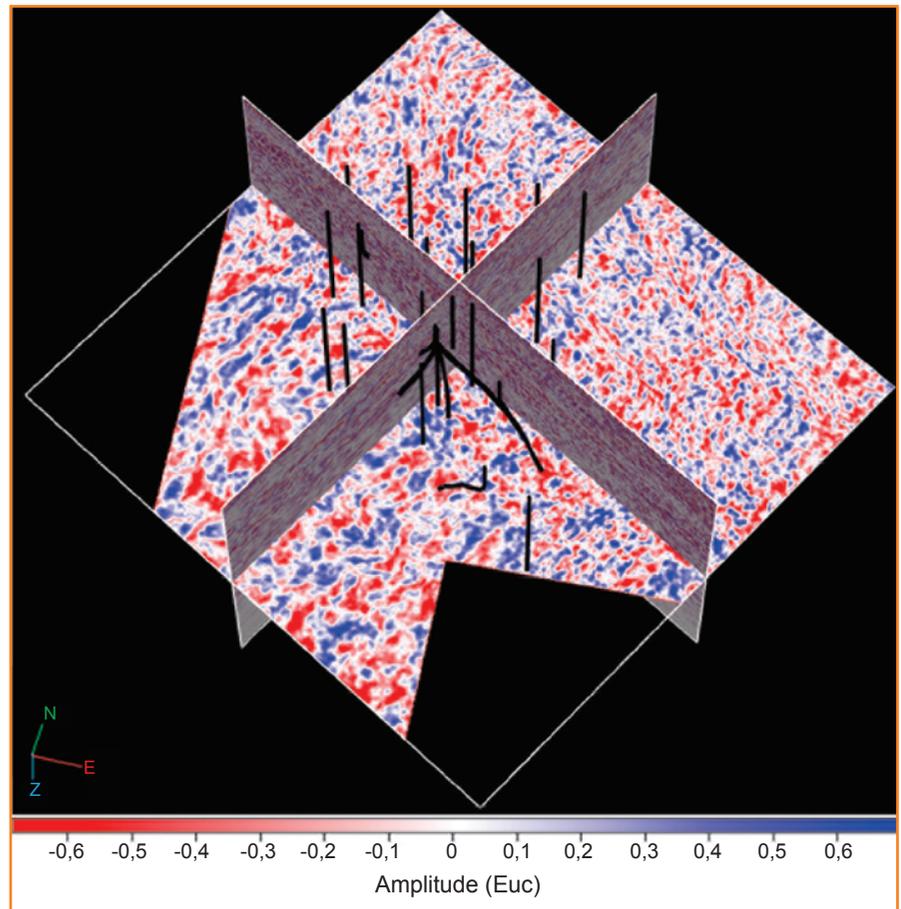


Figura 3 - Dado sísmico cortado na área do Campo A mostrando a distribuição dos poços. Imagem extraída do software Transform®.

Figure 3 - Seismic data of A Field showing distribution of wells. Image extracted from Transform® software.

básica de dados empregados para treinamento do método.

A fim de encontrar a melhor classificação possível para os poços do reservatório A e torná-la mais robusta, diferentes conjuntos de treinamento foram

Tabela 1

Cenários elaborados para análise de dados de testemunho. Além dos dados de perfis geofísicos, expoentes de Hölder, derivadas, impedância acústica e uma nova variável $V7$, que apresenta alta correlação com dados de calha, foram testados.

Table 1

Scenarios prepared for core data analysis. In addition to well-log data, Hölder exponents, derivatives, acoustic impedance, and a new variable $V7$, which shows high correlation with drill cuttings data, were tested.

	Cenários para classificação de testemunho								
	1	2	3	4	5	6	7	8	9
(Profundidade, DT , GR , $NPHI$, $RHOB$)	x	x	x	x	x	x	x	x	
Derivada		x							
Impedância Acústica			x		x	x	x		
Hölder (Perfis)				x	x				x
Hölder (GR)								x	
Hölder (IA)							x	x	
Variável $V7$						x	x	x	x

criados para teste de influência de cada variável na predição de testemunho, com variação segundo informações de impedância sísmica acústica e sintética dos poços, expoentes de Hölder e derivadas dos perfis elétricos (tabela 1).

Para classificação de eletrofácies foi realizado um primeiro teste, com a análise de perfis geofísicos, profundidade e impedância acústica, que se mostrou altamente correlacionada aos dados de calha. Essa classificação foi testada em alguns cenários como uma variável adicional para a classificação de dados de testemunho e denominada sétima variável (V7).

No primeiro cenário, os perfis geofísicos e a profundidade das amostras foram utilizados para treinamento do algoritmo SOM, constituindo o conjunto de treinamento usual para caracterização de eletrofácies (Bhatt e Helle, 2002).

No segundo cenário, os perfis geofísicos originais (*DT*, *GR*, *NPHI* e *RHOB*), foram derivados e tal informação foi adicionada ao conjunto de treinamento para avaliação do comportamento de oscilação do perfil em profundidade em regiões com a presença de fácies reservatório e não reservatório.

O terceiro cenário é formado pela adição de dados de impedância acústica (*IA*) sintética e de impedância acústica extraída da sísmica nos perfis geofísicos.

O quarto cenário consiste na inserção dos expoentes de Hölder de todos os perfis geofísicos no conjunto de treino utilizado pelo algoritmo.

O quinto cenário apresenta como conjunto de treino a combinação dos perfis básicos com os expoentes de Hölder e a *IA*.

A partir do sexto cenário, as classificações foram realizadas com adição da variável V7. Os valores de *IA* e V7 foram analisados com adição de expoentes de Hölder para a *IA* e depois somados com o coeficiente de Hölder para a variável *GR* e, por fim, treinados com a inserção dos expoentes de Hölder para todos os perfis.

considerações finais

impedância acústica (*IA*)

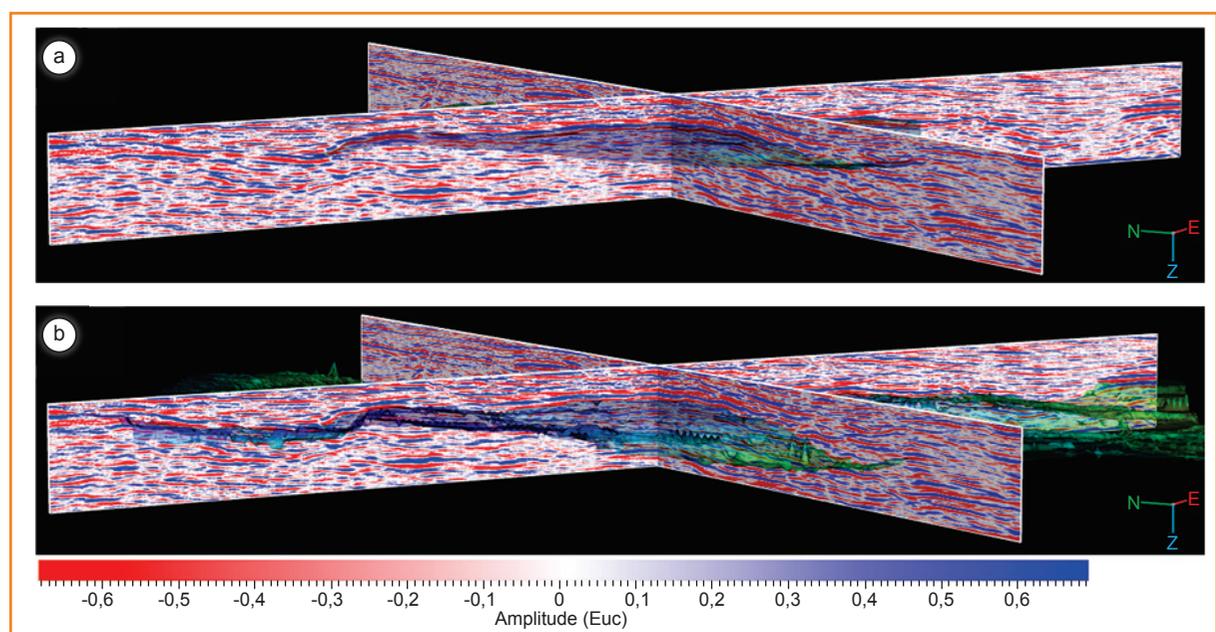
Os horizontes sísmicos interpretados e presentes na área do Reservatório Albiano do Campo A são o Macaé (fig. 4a) e o Quissamã (fig. 4b).

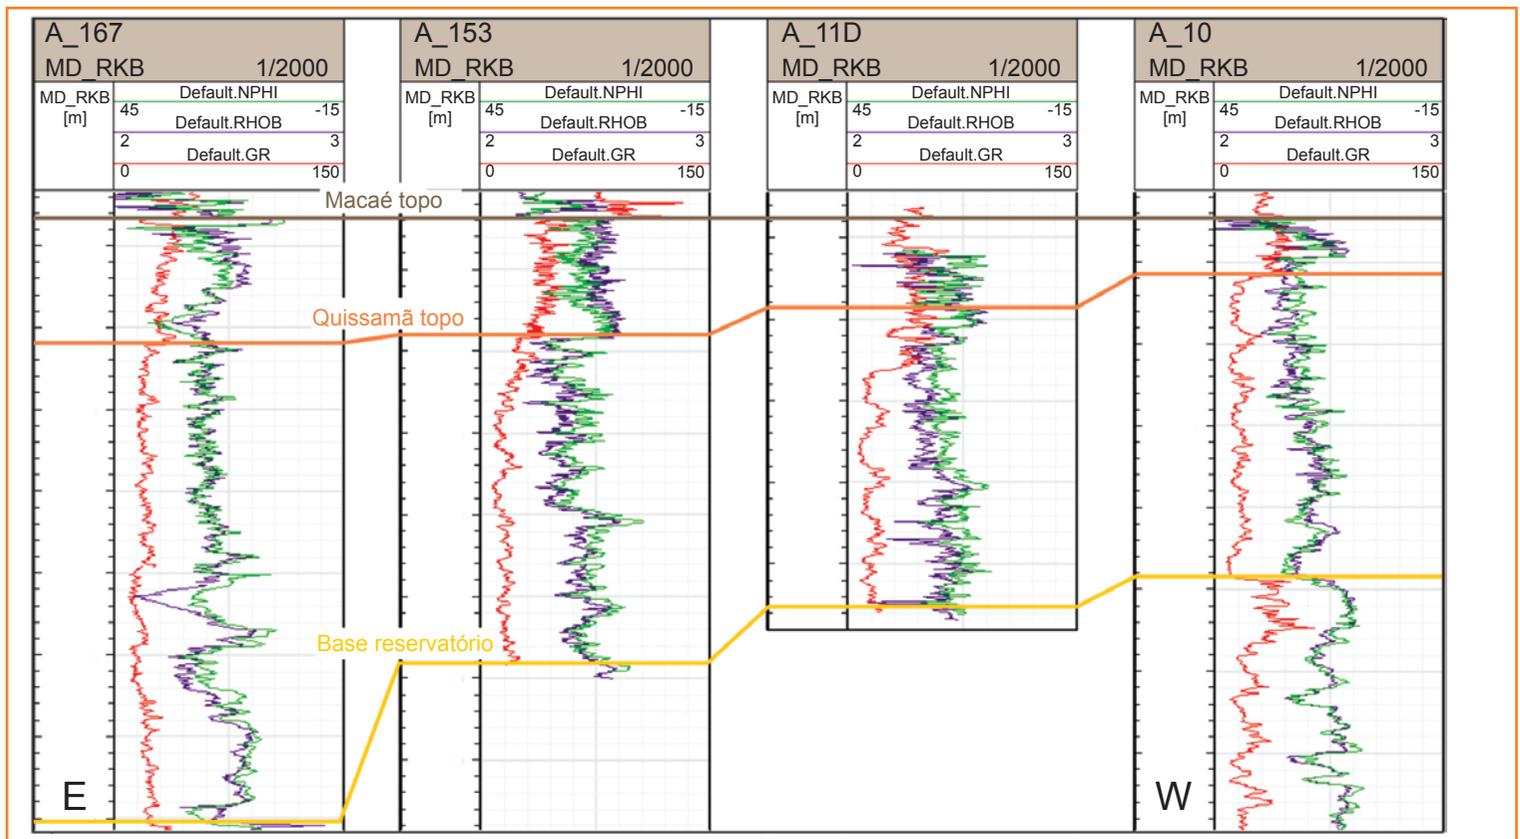
Os marcadores dos horizontes Macaé e Quissamã nos poços foram determinados com auxílio das curvas de *GR*, *NPHI* e *RHOB*. O horizonte Macaé é o topo do Grupo Macaé e foi determinado nos poços devido à expressiva queda de *GR* em comparação com os folhelhos da Formação Outeiro (fig. 5). O horizonte Macaé não está presente em todos os poços do Campo A.

O horizonte Quissamã é o topo do reservatório no Campo A e é identificável nos poços devido aos baixos valores de *GR* e suavização deste perfil em relação ao horizonte Macaé, composto por calcilitos e margas. A passagem do horizonte Macaé para o Quissamã também é muito bem marcada por um aumento da porosidade neutrônica (fig. 5).

Figura 4
Horizontes sísmicos interpretados na área do Reservatório Albiano do Campo A: a. Macaé; b. Quissamã. Imagem extraída do software Transform®.

Figure 4
Seismic horizons interpreted in the area of the Albian Reservoir of Field A: a. Macaé; b. Quissamã. Image extracted from Transform® software.





A base do reservatório foi definida devido a um ligeiro aumento do *GR* e queda da porosidade neutra (fig. 5).

O modelo básico da resposta sísmica sintética em tempos de ida e volta de um poço é assumido como sendo a convolução de uma forma de onda com a série de refletividade do poço, definida de perfis de velocidade e de densidade dos poços. O sismograma sintético em tempo foi determinado buscando maximizar as correlações cruzadas com o traço sísmico de referência sem modificar a informação do poço em profundidade. Foi gerado um modelo de velocidade 2D com a amarração do horizonte em tempo com os marcadores de poço. O algoritmo utilizado gera um modelo de superfície tempo-profundidade (STDm).

A janela de tempo utilizada para a criação dos sismogramas sintéticos usou o horizonte Macaé como topo e 2.250m como base para o modelo. Para a geração da inversão acústica do Campo A foram utilizados 17 poços.

Oito dos 17 poços não possuem os perfis *RHOB* e *DT* e alguns que os possuem podem não apresentar continuidade dentro da área de interesse. Por este motivo foi utilizada a equação de Gardner *et al.* (1974) para obter uma relação entre os perfis *RHOB* e *DT* a

fim de estimar o valor de um perfil a partir do outro, calculado segundo a equação 9:

$$\rho = 0.23V_p^{0.25} \quad (9)$$

Onde:

ρ = densidade de *bulk*;
 V_p = velocidade da onda.

Foram estimadas *wavelets* para cada poço utilizado. Estimar a *wavelet* do dado sísmico ao redor do dado de poço tem a vantagem de criar sismogramas sintéticos que respondem às mudanças laterais e verticais na *wavelet* em toda a área de interesse. Para a criação da *wavelet* global para o Reservatório A foram utilizadas as *wavelets* que geraram uma correlação acima de 0,7 (11 poços) para os sismogramas sintéticos em comparação com os observados. A *wavelet* é obtida pelo método dos mínimos quadrados (Broadhead, 2008).

A figura 6 mostra o ajuste sísmica-poço para o poço A78. O coeficiente de correlação traço sintético em comparação com o observado é de 0,774.

Com a *wavelet* global determinada, as amplitudes foram invertidas para refletividade (*r(t)*) através da inversão *sparse-spike* (Sacchi e Ulrych, 1996). Em seguida,

Figura 5

Seção E-W do Campo A mostrando os horizontes Macaé topo, Quissamã topo, e base do reservatório marcados nos poços. Imagem extraída do software Transform®.

Figure 5

E-W section of Field A showing the horizons Macaé (top) Quissamã (top), and base of the reservoir marked in the wells. Image extracted from Transform® software.

Solution Display for Well Bore: A_78

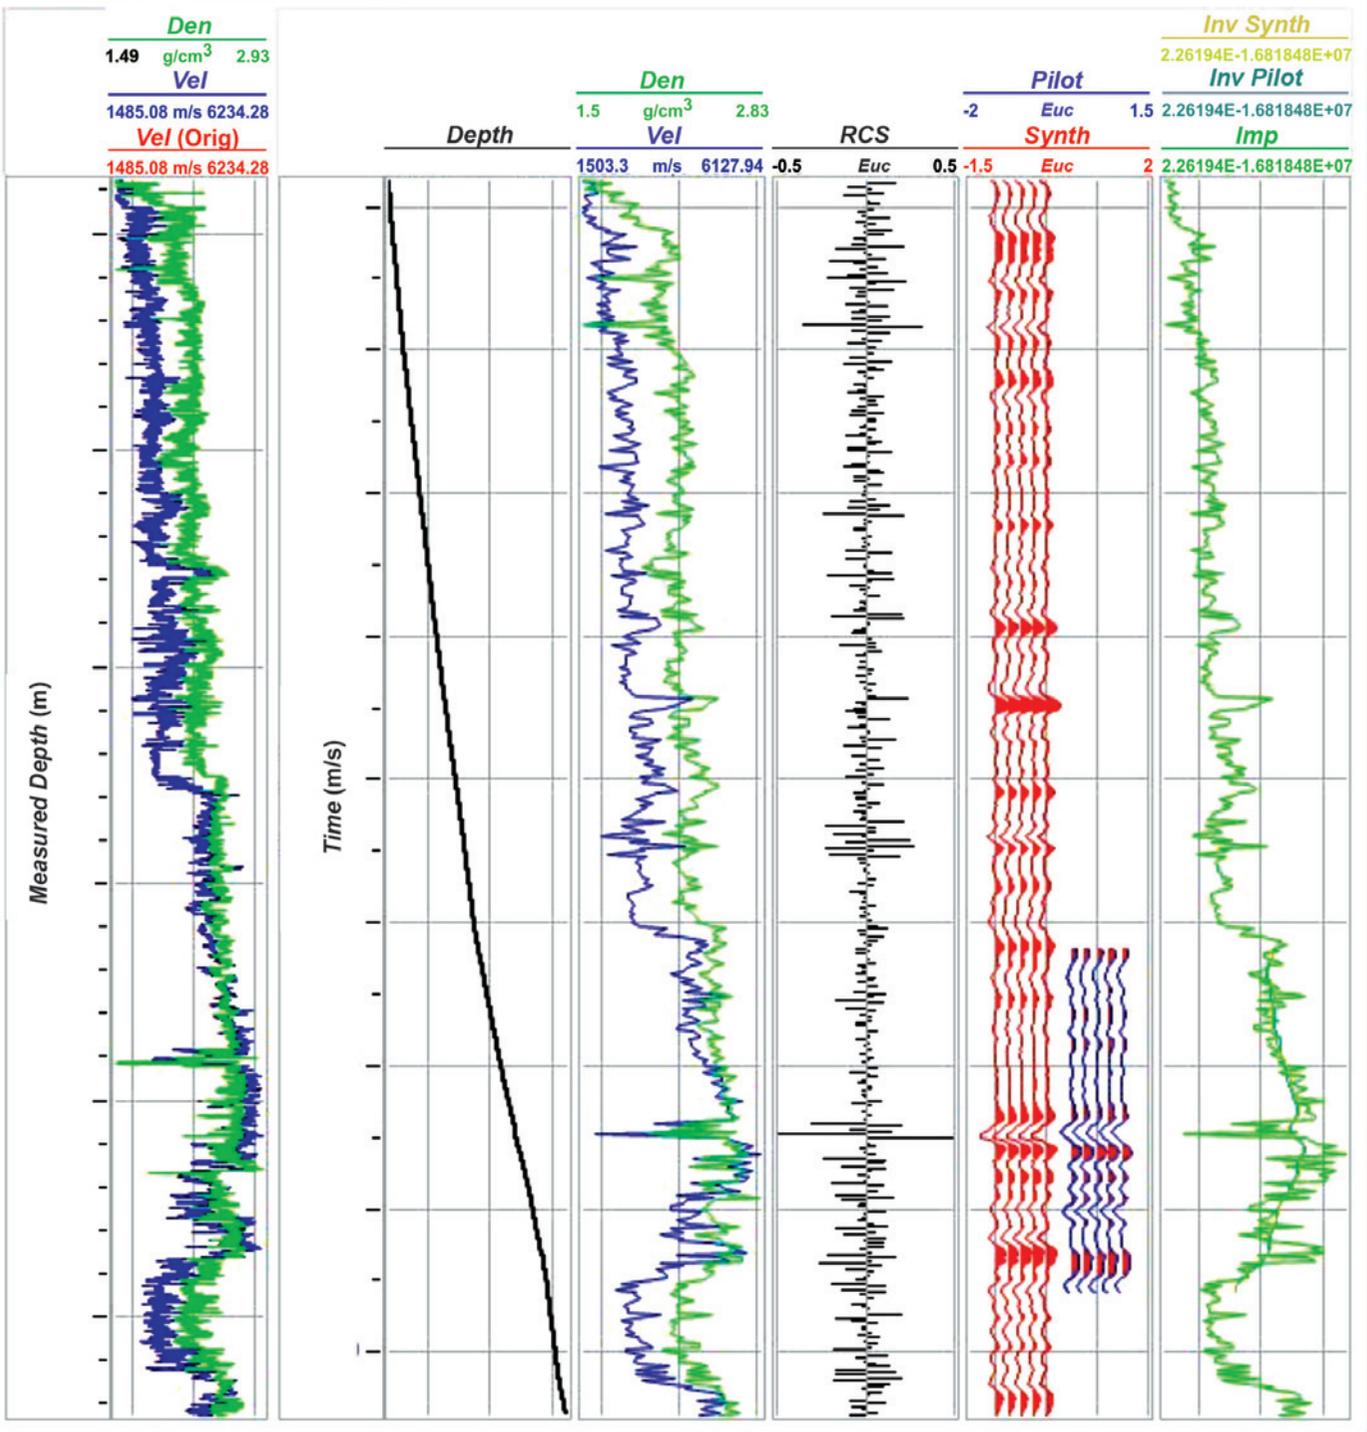


Figura 6 - Ajuste sísmica-poço para o Poço A78. Note a boa correlação entre o traço sintético (synth) em comparação com o observado (pilot). Imagem extraída do software Transform®.

Figure 6 - Seismic-well adjustment for Well A78. Note the positive correlation between the synthetic (synth) and the observed (pilot) data. Image extracted from Transform® software.

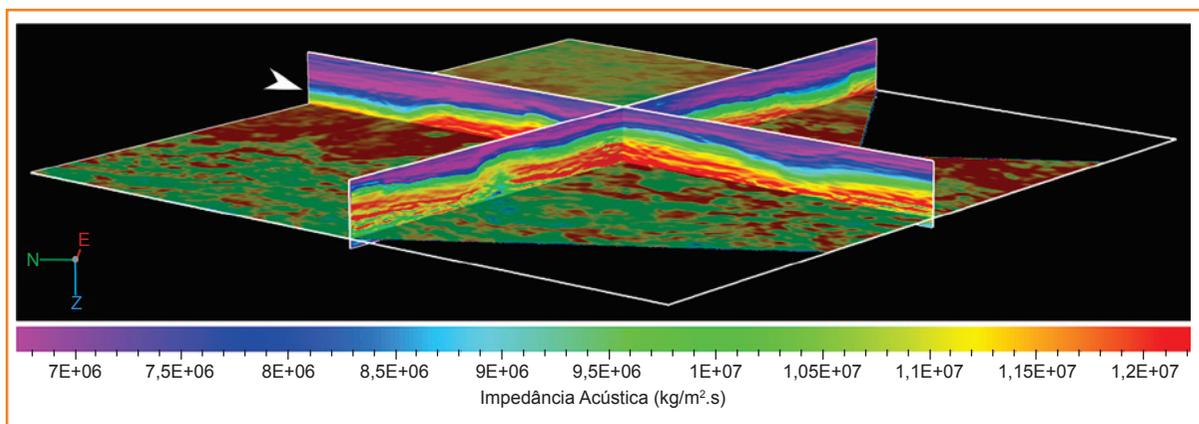


Figura 7
Cubo de impedância acústica obtido para o Campo A. A seta branca indica o topo do reservatório do Campo A identificado como topo da Formação Quissamã. Imagem extraída do software Transform®.

Figure 7
Acoustic impedance cube obtained for Field A. The white arrow indicates the top of the reservoir in Field A, identified as the top of the Quissamã Formation. Image extracted from Transform® software.

a inversão recursiva foi aplicada para cada sequência $r(t)$, realizando os passos descritos acima.

A figura 7 mostra o resultado da inversão para uma janela de tempo de 1.200m a 2.250m.

Os altos coeficientes de correlação entre os traços sintéticos e os traços observados indicam que os ajustes sísmica-poços foram realizados de maneira adequada, embora nem todos os eventos observados tenham sido mapeados nos traços sintéticos.

classificação de fácies por SOM

A primeira classificação de eletrofácies realizada com os dados de perfis geofísicos, profundidade e impedância acústica apresentou correlação de 86,75% com dados de calha. Esta classificação, chamada de variável V7, também está inserida no conjunto de

treinamento do melhor cenário para caracterização de testemunho, que também inclui informações de IA, para a qual se obteve acerto de 77,24% (tabela 2).

Para classificação da variável V7, os dados foram treinados pelo método de SOM e separados em um mapa com dimensões de 17 x 11, com erro final de quantização (eq) igual a 0,608 e erro final topográfico (et) igual a 0,085.

O maior detalhe da classificação da matriz-U é mostrado pela figura 8. As regiões caracterizadas por cores frias representam homogeneidade dos dados, enquanto as regiões de cores quentes representam regiões com heterogeneidade. Assim, regiões frias (diferentes tons de azul) representam possíveis grupos com mesmo padrão, separadas por regiões de cores quentes.

Pela imagem é possível observar que apenas uma fácies se destaca das demais, a fácies marga, evidenciada pelo círculo 1, as demais classes apresentam

Tabela 2
Resultados obtidos para a classificação da variável V7 (altamente correlacionada aos dados de calha) e testemunho, a partir de eletrofácies do Reservatório A para diferentes cenários. Em destaque os melhores resultados.

Table 2
Results obtained for the classification of the V7 variable (highly correlated to drill cuttings data) and cores, based on electrofacies from Reservoir A for different scenarios. The best results are highlighted.

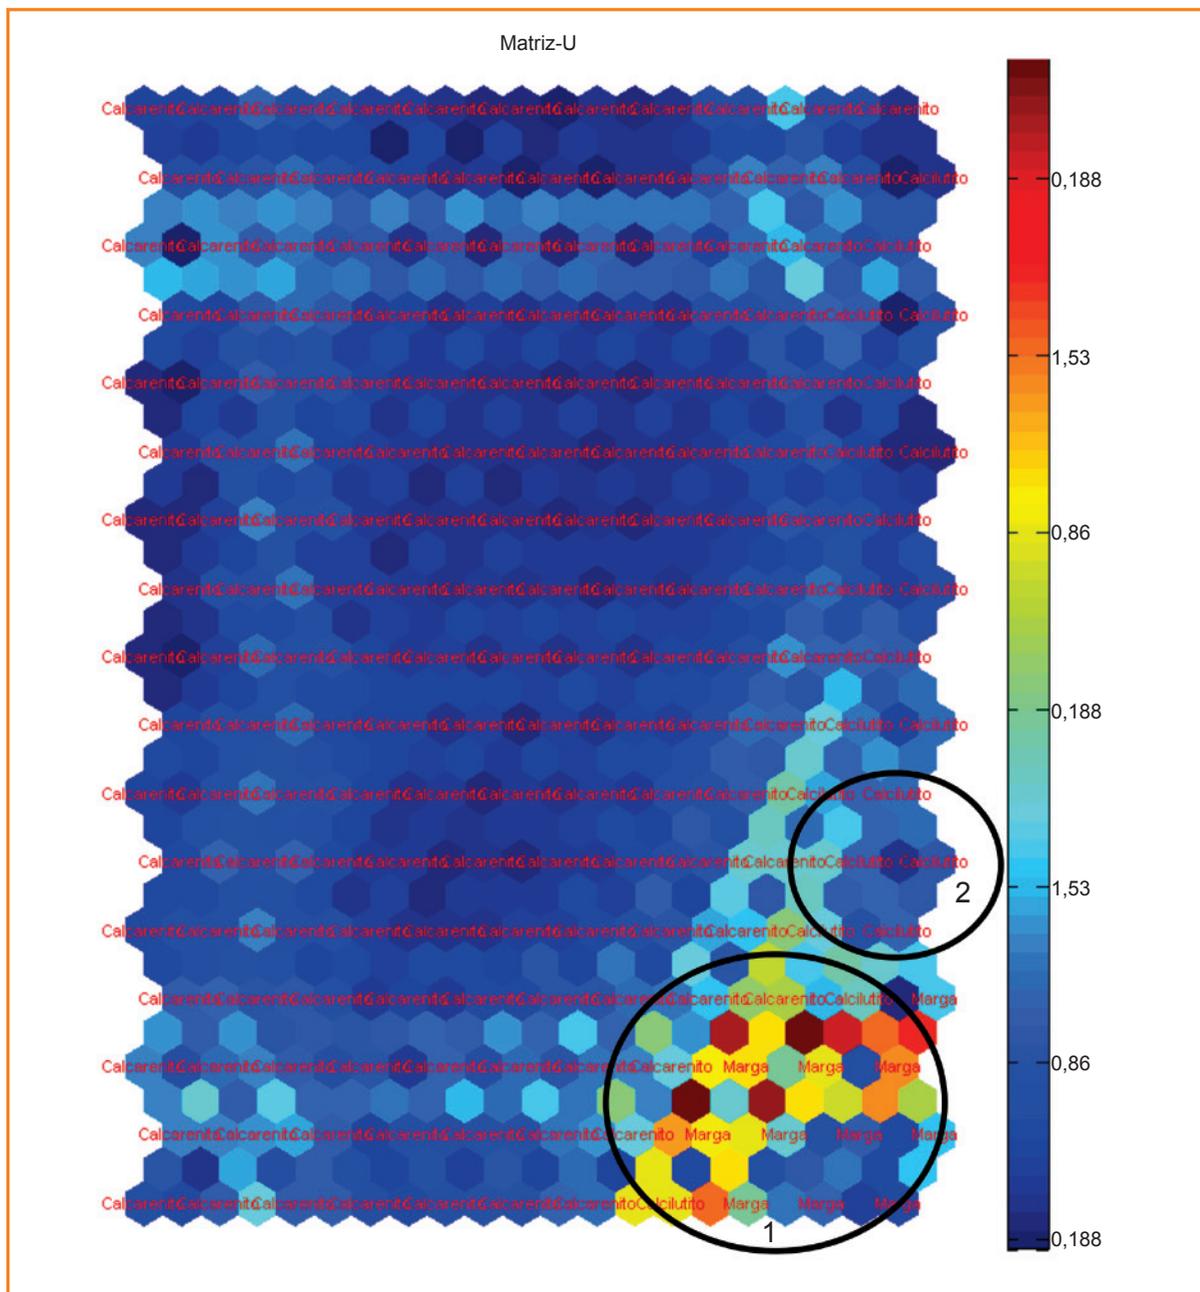
Acerto (%) da classificação de eletrofácies carbonáticas com redes neurais não supervisionadas (SOM)									
	Cenários								
	1	2	3	4	5	6	7	8	9
	Normal (DEPTH, DT, GR, NPFI, RHOB)	Derivada	IA (Sísmica e sintética)	Hölder	Hölder + IA	IA + V7	IA + V7 + Hölder IA	V7 + Hölder IA + GR	V7 + Hölder
V7	82,78	83,80	86,75	82,25	83,50				
Testemunho	61,34	69,97	76,14	68,70	73,60	77,24	73,69	71,40	71,15

Figura 8

Imagem da matriz-U obtida para a classificação da variável V7. Estão destacadas em círculos as regiões correlacionadas às fácies marga (círculo 1) e calcilitos (círculo 2). Imagem gerada pelo pacote de Vesanto *et al.* (2000).

Figure 8

U-matrix image obtained for the classification of the V7 variable. The areas correlated to the marl facies (circle 1) and calcilitites (circle 2) are highlighted. Image generated by Vesanto *et al.* (2000) toolbox.



similaridade dos dados e por isso representam fácies com menores níveis de acerto, como a fácies calcilitito, representada pelo círculo 2. As demais regiões são caracterizadas por dados de calcarenito.

Para esta classificação correlacionada às amostras de calha, a matriz de confusão (tabela 3) mostra na oitava coluna à direita o erro associado aos dados de calha e na penúltima linha o erro associado à classificação desses dados com o método de SOM. A última célula da matriz, abaixo à direita, representa o acerto total da classificação de eletrofácies, enquanto a diagonal da matriz representa a quantidade de amostras classificadas corretamente para cada fácies.

Nesta primeira classificação não houve correlação com arenitos, cuja fácies o método de SOM não conseguiu classificar corretamente, devido à baixa representatividade (0,024%) do grupo no conjunto de dados. Outro resultado importante evidenciado pela matriz de confusão é o erro associado à fácies folhelhos, estimado em 68,9% que em geral foi correlacionado com marga, devido a maior influência desta fácies, que possui 11 vezes mais dados e representa a classe com maior porcentagem de acerto nesta classificação.

Embora as informações de calha apresentem erros relacionados à profundidade das informações

Correlação da variável V7 com dados de calha									
Dados de Calha		Calcilutito	Calcissiltito	Calcarenito	Arenito	Folhelho	Marga	Erro	Acerto global
	Calcilutito	1.821	46	1.060	0	30	312	0,44	
	Calcissiltito	68	245	308	0	0	0	0,61	
	Calcarenito	540	119	14.849	0	11	21	0,04	
	Arenito	1	0	1	0	1	49	1,00	
	Folhelho	27	0	5	0	41	59	0,69	
	Marga	108	2	20	0	9	1.362	0,09	
Erro	0,29	0,41	0,09	0,00	0,55	0,24	0,13		
Acerto global								0,87	

Tabela 3

Matriz de confusão obtida para a classificação de dados de calha do Campo A com SOM.

Table 3

Confusion matrix obtained for the classification of drill cuttings data from Field A using SOM.

e mistura de litologias de diferentes intervalos, essas informações foram suficientes para identificação dos agrupamentos obtidos na análise do SOM.

Segundo os poços testemunhados do Reservatório A, a fácies marga apresenta intervalos de perfis *GR* [25; 100] (gAPI), *RHOB* [2,2; 2,6] (g/cm³) e *DT* [70; 110] (us/m), enquanto a fácies folhelho possui intervalos de perfis *GR* [30; 90] (gAPI), *RHOB* [2,2; 2,4] (g/cm³) e *DT* [75; 110] (us/m). Analisando-se os perfis *GR*, *RHOB* e *DR*, nota-se que os intervalos de valores da fácies folhelho estão contidos nos intervalos da fácies marga, dificultando a classificação destas fácies.

Os demais cenários apresentaram desempenho inferior. A classificação obtida com a adição dos expoentes de Hölder não apresenta alta correlação com os dados de calha, confundindo o algoritmo pelo acréscimo do número de variáveis analisadas, que aumenta a dimensão dos dados de treino. A classificação com dados sobre a derivada dos perfis geofísicos demonstrou resultados muito próximos da suíte básica analisada, composta pelos perfis: *DT*, *GR*, *NPHI* e *RHOB*.

Posteriormente foram analisados os cenários para análise de correlação com dados de testemunho. Com média de acerto inferior à classificação de V7, o melhor cenário foi encontrado para o sexto conjunto de treino que utiliza a variável V7 descrita anteriormente e adição de valores de *IA* sintética e sísmica.

Estes dados foram treinados com SOM, para o qual o mapa gerado apresentou dimensões de 15 x 11, erro final de quantização (*qe*) igual a 0,676 e erro final topográfico (*et*) igual a 0,052.

A classificação da matriz-U segundo dados de testemunho pode ser observada na figura 9, cuja área é composta predominantemente por regiões de cor azul, indicando dados homogêneos representantes de fácies correlacionadas a reservatório e cimento, o que torna a separação uma tarefa que necessita de maior sensibilidade do algoritmo. A região que mais se destaca é a correlacionada à fácies não reservatório (representada pela região do círculo 1) e por isso representa a fácies com maior acerto. As fácies cimento (região caracterizada pelo círculo 2) e possível reservatório (região destacada pelo círculo 3) possuem características intermediárias entre não reservatório e reservatório e, por isso, apresentam menores índices de correlação.

A classificação das fácies em reservatório e não reservatório apresentou índice de correlação em torno de 85%, enquanto este índice para as fácies classificadas como possível reservatório e cimento caiu para aproximadamente 70% (tabela 4). A fácies cimento engloba diversas litologias e não apresenta um único padrão específico de comportamento nos perfis geofísicos. Tal evento pode ter gerado o menor percentual na classificação.

Apesar da diminuição da taxa de correlação para a fácies cimento em relação às demais, o percentual global de 77% ainda é relevante e este cenário pode ser utilizado como uma alternativa na caracterização de perfis geofísicos quanto à classificação de testemunho, cuja análise tradicional, representada pela classificação do cenário 1, apresenta desempenho 16% menor. Ainda assim, mediante desempenho de classificação dos dois poços testemunhados, o

Figura 9
 Imagem da matriz-U obtida para a classificação de dados de testemunho do Campo A. As regiões circuladas representam áreas de padrões associados a diferentes fácies: 1) não reservatório, 2) cimento, 3) possível reservatório e 4) reservatório. Imagem gerada pelo pacote de Vesanto et al. (2000).

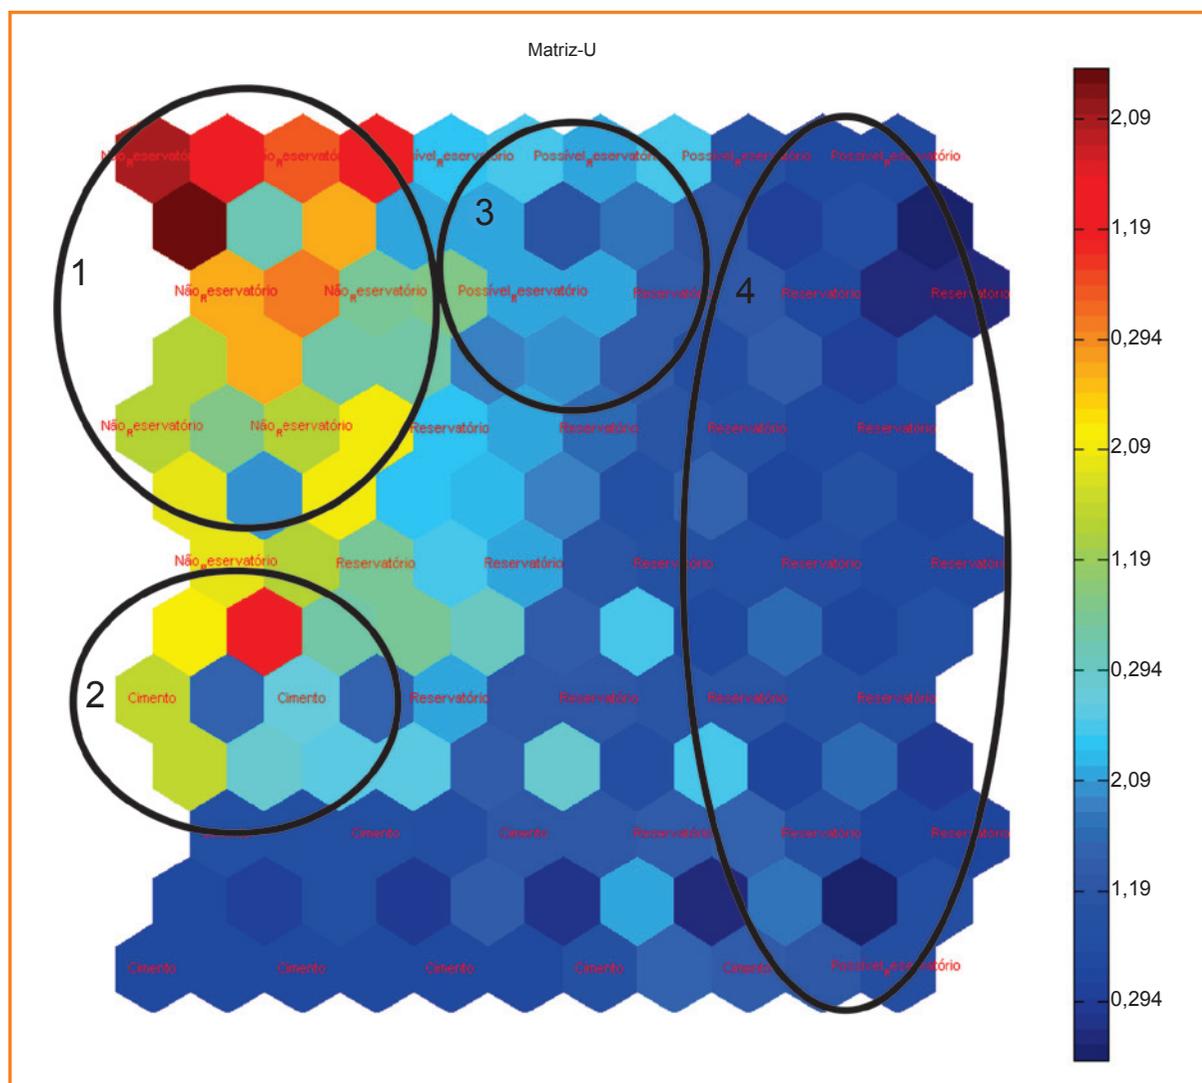


Figure 9
 U-matrix image obtained for classification of core data of Field A. The circled regions represent areas with patterns associated with different facies: 1) non-reservoir; 2) cement; 3) possible reservoir; 4) reservoir. Image generated by Vesanto toolbox et al. (2000).

volume de óleo estimado nesta classificação é 7% mais otimista do que no cenário real.

Para este cenário, a classificação obtida para os poços testemunhados pode ser vista nas figuras 10 e 11:

A adição de expoentes Hölder não melhorou o desempenho da classificação de dados de testemunho, embora seus resultados estejam acima da média da classificação dos dados compostos apenas

Tabela 4
 Matriz de confusão obtida para a classificação de dados de testemunho do Campo A com SOM.

Table 4
 Confusion matrix obtained for the classification of core data from Field A by SOM.

Correlação de dados de testemunho com a classificação SOM							
Testemunho		Reservatório	Possível Reservatório	Não Reservatório	Cimento	Erro	Acerto global
	Reservatório	340	36	5	24	0,16	
	Possível Reservatório	53	193	19	14	0,31	
	Não Reservatório	10	13	170	7	0,15	
	Cimento	45	38	5	210	0,30	
	Erro	0,24	0,31	0,15	0,18	0,23	
Acerto global						0,77	

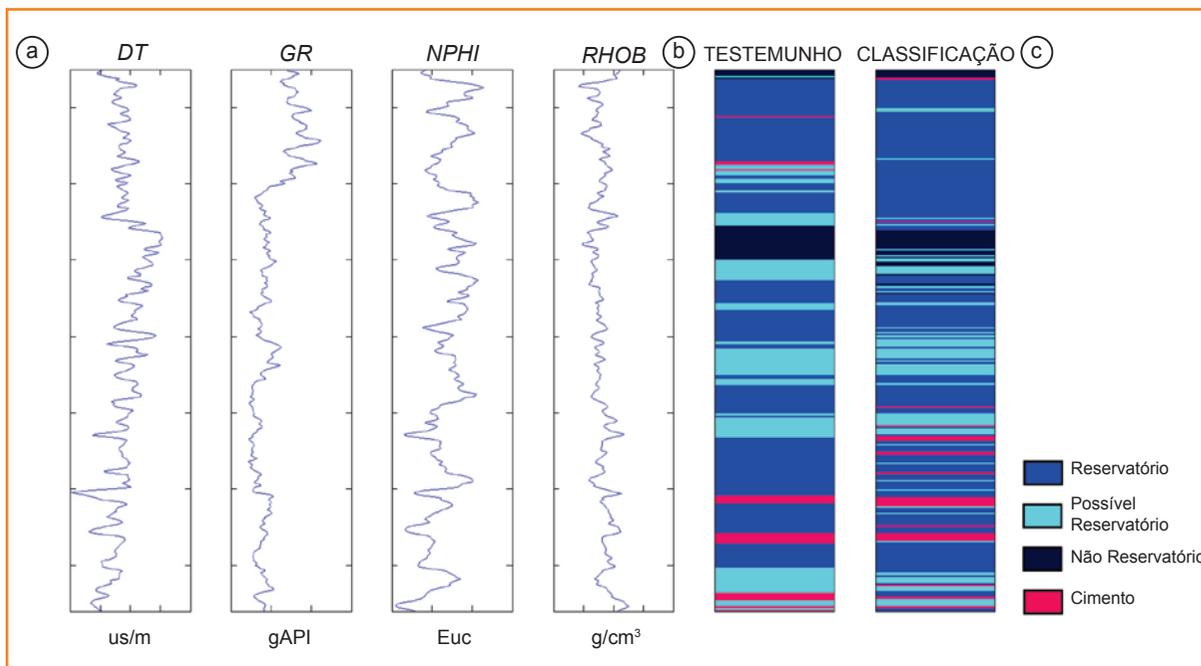


Figura 10
Resultado da classificação de fácies de testemunho para o Poço A_3. Imagem gerada no software Matlab®.

Figure 10
Result of the classification of core facies for Well A_3. Image generated by Matlab® software.

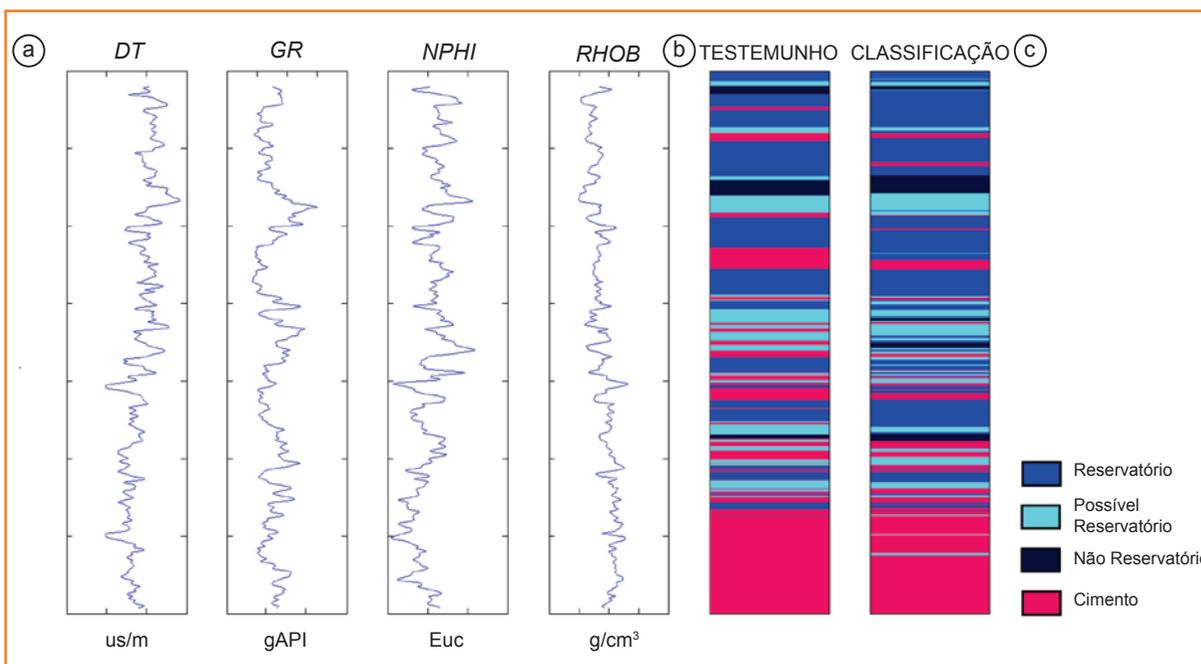


Figura 11
Resultado da classificação de fácies de testemunho para o Poço A_10. Imagem gerada no software Matlab®.

Figure 11
Results of the classification of core facies for Well A_10. Image generated by Matlab® software.

da suíte básica e, para alguns cenários, sejam melhores que a utilização de derivadas dos perfis.

conclusões

A caracterização de eletrofácies carbonáticas representa um grande desafio, devido à grande heterogeneidade dos reservatórios. A presença

de camadas delgadas e a diversidade petrofísica do campo alteram os valores de perfis geofísicos, que, somados à lacuna do conhecimento das distribuições deposicionais da área de estudo, levam a incertezas que precisam ser minimizadas. Para solucionar este problema, a técnica de redes neurais (SOM) demonstrou ser uma ferramenta viável na predição automática de eletrofácies a partir da combinação de perfis geofísicos, expoentes de Hölder, derivadas de perfis e impedância acústica (IA).

Os seis padrões dos perfis geofísicos e impedância acústica, encontrados pelo algoritmo SOM, se mostraram altamente correlacionados aos dados de calha, que também apresentam seis litologias. Contudo, outros testes buscando diferentes números de agrupamentos não foram realizados.

A quantidade de dados disponibilizada para correlação do treinamento do algoritmo com dados de calha e testemunho é um fator decisivo na qualidade da classificação. Os dados de calha, presentes em 16 poços, garantem o melhor desempenho da validação dos algoritmos em relação aos dois poços, cujas amostras foram utilizadas para correlação na classificação de valores de testemunho devido à subamostragem. Por isso, os resultados da classificação de litologias (altamente correlacionados aos dados de calha) foram utilizados na classificação de fácies, a fim de torná-la mais robusta. Entretanto, tais dados possuem incertezas associadas à profundidade e, por se tratar de análises de amostras pontuais, podem desconsiderar a presença significativa de outras litologias.

Neste trabalho, em que a escassez dos dados de testemunho compromete a classificação de eletrofácies do reservatório, diferentes cenários foram comparados. Verificou-se que a inserção da classificação inicial, altamente correlacionada aos dados de calha, como uma nova variável adicionada aos dados sísmicos, no caso o atributo *IA*, é relevante para o treinamento do algoritmo, contribuindo para o melhor desempenho da técnica e aumentando os índices de correlação da classificação das amostras de poço em até 4,5% e dos testemunhos em até 16%, se comparado com o desempenho da classificação do cenário 1, composto apenas pelos perfis geofísicos e pela profundidade.

Em geral, os erros cometidos na classificação correlacionada aos dados de calha estão associados a classes semelhantes. Ou seja, as fácies selantes, como marga e folhelho, não são confundidas com fácies reservatórios, calcarenitos. Entretanto, para a predição de dados de testemunho nos poços, a fácies cimento foi confundida com as fácies reservatório e possível reservatório, tornando a estimativa do volume de petróleo 7% mais otimista que o cenário real, com base nos dois poços analisados. Tais erros podem estar associados à complexidade do campo carbonático e à limitação de amostragem dos dados utilizados para classificação dos grupos, que impactaram principalmente na previsão de dados de testemunho com diferentes litologias pouco amostradas.

Entretanto, o bom desempenho das classificações de testemunho possibilita o uso da técnica testada como ferramenta auxiliar na caracterização de eletrofácies.

agradecimentos

Os autores agradecem à Petrobras pelo financiamento do Projeto “Métodos quantitativos aplicados ao estudo de reservatórios carbonáticos” e por disponibilizar os dados utilizados neste trabalho. As empresas Transform e Roxar são agradecidas pela doação das licenças dos *softwares* Transform e RMS, respectivamente. Também agradecemos à geofísica Gabriela Castillo (Universidade Estadual Paulista - Unesp) pela disponibilização dos horizontes sísmicos interpretados.

referências bibliográficas

ÁLVAREZ, G.; SANSÓ, B.; MICHELENA, R. J.; JIMÉNEZ, J. R. Lithologic characterization of a reservoir using continuous-wavelet transforms. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 41, n. 1, p. 59-65, Jan. 2003.

ARZUMAN, S. **Comparison of Geostatistics and Artificial Neural Networks in Reservoir Property Estimation**. 2009. 145 f. Tese (Doutorado) – Departamento de Engenharia Geológica, The Middle East Technical University, Ankara-Eskişehir, 2009.

AVSETH, P.; MUKERJU, T.; MAVKO, G. **Quantitative seismic interpretation**. Cambridge: Cambridge University Press, 2005. 359 p.

BERTEUSSEN, K. A.; URSIN, B. Approximate computation of the acoustic impedance from seismic data. **Geophysics**, Tulsa, v. 48, n. 10, p. 1351-1358, Oct. 1983.

BHATT, A.; HELLE, H. B. Determination of facies from well logs using modular neural networks. **Petroleum Geoscience**, London, v. 8, n. 3, p. 217-228, Aug. 2002.

BROADHEAD, M. K. The impact of random noise on seismic wavelet estimation, **The Leading Edge**, Los Angeles, v. 27, n. 2, p. 226-230, Feb. 2008.

COLÉOU, T.; POUPON, M.; AZBEL, K. Unsupervised seismic facies classification: a review and comparison of techniques and implementation. **The Leading Edge**, Los Angeles, v. 22, n. 10, p. 942-953, Oct. 2003.

- DAVIES, D. L.; BOULDIN, D. W. A Cluster separation measure. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, v. PAMI-1, n. 2, p. 224-227, Apr. 1979.
- DRUMMOND, R. D.; VIDAL, A. C. Comparação entre as técnicas multivariadas MAF e PCA aplicadas na classificação de eletrofácies. **Revista Brasileira de Geofísica**, São Paulo, v. 29, n. 3, p. 497-509, jul./set. 2011.
- EASTLEY, K.; UNSTEAD, P.; KLOOSTERMAN, H. J. Case study: using seismic inversion to constrain “proved area” definition. **The Leading Edge**, Los Angeles, v. 31, n. 10, p. 1082-1089, Sept. 2012.
- ESPOSITO, A. M.; GIUDICEPIETRO, F.; D’AURIA, L.; SCARPETTA, S.; MARTINI, M.G.; COLTELLI, M.; MARINARO, M. Unsupervised neural analysis of very-long-period events at Stromboli Volcano using the self-organizing maps. **Bulletin of the Seismological Society of America**, Stanford, v. 98, n. 5, p. 2449-2459, Oct. 2008.
- GARDNER, G. H. F.; GARDNER, L. W.; GREGORY, A. R. Formation velocity and density – the diagnostic basics for stratigraphic traps. **Geophysics**, Tulsa, v. 39, n. 6, p. 770-780, Dec. 1974.
- GROSSMAN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. **SIAM Journal on Mathematical Analysis**, Philadelphia, v. 15, n. 4, p. 723-736, July 1984.
- HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.
- KHEDAIRIA, S.; KHADIR, M. T. Self-organizing map and k-means for meteorological day type identification for the region of Annaba-Algeria. In: COMPUTER INFORMATION SYSTEMS AND INDUSTRIAL MANAGEMENT APPLICATIONS, 7., 2008, Ostrava. **Proceedings...** Ostrava: The IEEE Computer Society, 2008. p. 91-96.
- HERRMANN, F.; STARK, C. A scale attribute for texture in well and seismic data. In: SEG ANNUAL INTERNATIONAL MEETING, 70., 2000, Calgary. **Proceedings...** [Tulsa]: Society of Exploration Geophysicists, 2000. p. 2063-2066.
- KOHONEN, T. **Self-organizing maps**. 3. ed. Berlin: Springer, 2001. 501 p.
- KURODA, M. C.; VIDAL, A. C.; LEITE, E. P. L.; DRUMMOND, R. D. Electrofacies characterization using self-organizing maps. **Revista Brasileira de Geofísica**, São Paulo, v. 30 n. 3, p. 287-299, 2012.
- LEITE, E. P.; SOUZA FILHO C. R. Mapas auto-organizáveis aplicados ao mapeamento do potencial mineral na região de Serra Leste, Província Mineral de Carajás, Pará. **Revista Brasileira de Geofísica**, v. 28, n. 3, p. 397-409, jul./set. 2010.
- LI, C. F. **Scaling and wavelet-based singularity analyses for geological and geophysical interpretation**. 2002. 130 f. Tese (Doutorado) – University of Tulsa, Tulsa, 2002.
- LI, C. F.; LINER, C. Singularity exponent from wavelet-based multiscale analysis: a new seismic attribute. **Chinese Journal of Geophysics**, New York, v. 48, n. 4, p. 953-959, 2005.
- LI, C. F.; LINER, C. Wavelet-based detection of singularities in acoustic impedances from surface seismic reflection data. **Geophysics**, Tulsa, v. 73, n. 1, p. v1-v9, Jan./Feb. 2008.
- LOUBES, J. M.; VAN DE GEER, S. Adaptive estimation in regression, using soft thresholding type penalties. **Statistica Neerlandica**, Rotterdam, v. 56, n. 4, p. 453-478, Nov. 2002.
- LYONS, W. J.; HERRMANN, F.; GROTZINGER, John. Singularity analysis: a tool for extracting lithologic and stratigraphic content from seismic data. In: SEG ANNUAL INTERNATIONAL MEETING, 71., 2001, San Antonio. **Proceedings...** [Tulsa]: Society of Exploration Geophysicists, 2001. p. 1-14.
- MALLAT, S. A **wavelet tour of signal processing**. London: Academic Press, 1998. 577 p.
- MALLAT, S.; HWANG, W. L. Singularity detection and processing with wavelets. **IEEE Transactions on Information Theory**, New York, v. 38, n. 2, p. 617-643, Mar. 1992.
- MALLAT, S.; ZHONG, S. Characterization of signals from multiscale edges. **IEEE Transactions on**

Pattern Analysis and Machine Intelligence, New York, v. 14, n. 7, p. 710-732, July 1992.

MATOS, M. C.; OSORIO, P. L. M.; JOHANN, P. R. S., Unsupervised seismic facies analysis using wavelet transform and self-organizing maps. **Geophysics**, Tulsa, v. 72, n. 1, p. P9-P21, Jan./ Feb. 2007.

MELDAHL, P.; HEGGLAND, R; BRIL, B.; GROOT, P. Identifying faults and gas chimneys using multiattributes and neural networks. **The Leading Edge**, Los Angeles, v. 20, n. 5, p. 474-482, May 2001.

OLDENBURG, D. W.; SCHEUER, T.; LEVY, T. Recovery of the acoustic impedance from reflection seismograms. **Geophysics**, Tulsa, v. 48, n. 10, p. 1318-1337, Oct. 1983.

POULTON, M. M. (Ed.). **Computational neural networks for geophysical data processing**. New York: Pergamon, 2001. 335 p.

RUSSEL, B. H. **Introduction to seismic inversion methods**. Tulsa: Society of Exploration Geophysicists, 1988. (Course notes series, n. 2).

SACCHI, M. D.; ULRICH, T. J. Bayesian Regularization of some seismic operators. In: HANSON, K. M.; SILVER, R. N. (Ed.). **Maximum entropy and Bayesian Methods**, Boston: Kluwer Academic Publishers, 1996. p. 431-436.

SAGGAF, M. M.; NEBRIJA, E. L. Estimation of lithologies and depositional facies from wire-line logs. **AAPG Bulletin**, Tulsa, v. 84, n. 10, p. 1633-1646, 2000.

SANCEVERO, S. S.; REMACRE, A. Z.; PORTUGAL, R. S. O papel da inversão para a impedância acústica no processo de caracterização sísmica de reservatórios. **Revista Brasileira de Geofísica**, São Paulo, v. 24, n. 4, p. 495-512, out./nov. 2006.

SEURET, S.; GILBERT, A. Pointwise Hölder exponent estimation in data network traffic. In: INTERNATIONAL TELETRAFFIC CONGRESS WORKSHOP, 2000, Monterey. **Proceedings**... Monterey: [s.n.], 2000. p. 1-10.

STUNDNER, M.; OBERWINKLER, C. Self-organizing maps for lithofacies identification and permeability prediction. In: SPE ANNUAL TECHNICAL CONFERENCE AND EXHIBITION, 2004, Houston. **Proceedings**... [Richardson]: Society of Petroleum Engineers, 2004. p. 1-8.

TARANTOLA, A.; VALETTE, B. Inverse problems = quest for information. **Journal of Geophysics**, Berlin, v. 50, p. 159-170, 1982.

TU, C.; HWANG, W. Analysis of singularities from modulus maxima of complex wavelets. **IEEE Transactions on Information Theory**, New York, v. 51, n. 3, p. 1049-1062, Mar. 2005.

VESANTO, J.; HIMBERG, J.; ALHONIEMI, E.; PARHANKANGAS, J. **SOM toolbox for matlab 5**. Finland: Helsinki University of Technology, 2000. 59 p. (Technical Report, A57).

YANG, Y.; APLIN, A. C.; LARTER, S. R. Quantitative assessment of mudstone lithology using geophysical wireline logs and artificial neural networks. **Petroleum Geoscience**, United Kingdom, v. 10, n. 2, p. 141-151, Apr. 2004.

bibliografia

BJORCK, A. **Numerical methods for least squares problems**. Philadelphia: Society for Industrial and Applied Mathematics, 1996. 408 p.

expanded abstract

One of the first topics in reservoir characterization is the facies classification from well log and seismic data. Therefore, the application of efficient strategies is an important issue in reservoir characterization and modeling.

High geological and petrophysical carbonate reservoir heterogeneity require the development of multivariate techniques, integrating information to improve the computational capacity of facies pattern recognition.

So, in order to minimize facies interpretation risks, this work shows an application of an unsupervised neural network, Self-Organizing Maps (SOM). Widely used in geophysical problems, this method was developed by Kohonen, in 2001, and it is inspired by brain works, used to recognition, classification and generalization of patterns. This tool is guided by data and during its training it is able to adapt and develop multivariate and nonlinear relationships.

The method is applied in a carbonate reservoir Albian, in Campos Basin, which are available information about 3D seismic amplitude and 26 boreholes, with well logs: sonic (DT), neutron porosity (NPHI), density (RHOB) and gamma ray (GR). Furthermore, from this field we have values of cutting data (16 boreholes) and core data (2 boreholes). Cutting data describes six facies: sandstone, calcilutite, calcisiltite, calcarenite, marl and shale, and core data describes four classes: reservoir (grainstone), possible reservoir (packstone), non-reservoir (wackstone, floatstone, carbonate breccia, marls and mudstone), and cement (all cemented facies).

The first test of electrofacies classification by SOM was done for the basic suit of well log data (DT, NPHI, RHOB and GR), but it showed a low performance of 61.34%. For this reason, different strategies were created to improve facies classification, in two steps, described below, with integration of all available information and calculated data of different methods combination, as derivative data, application of Hölder exponent and acoustic impedance data.

The derivative of well log data was analyzed to evaluate the oscillation behavior of the well logs in depth. In this way, interfaces can be highlighted and help the identification of thin beds.

Obtained by inversion methods, the acoustic impedance seeks to eliminate ambiguities of seismic reflection, incorporating information and

petrophysical principles in seismic interpretation, transforming amplitudes in elastic properties and adding information which cannot be extracted from conventional seismic interpretation.

In this context, the technique of seismic inversion data into acoustic impedance has been an excellent method of data integration of well logs and seismic data. The advantage of this type of inversion is due to the fact that the impedance is associated with rock properties (like lithology, porosity, and permeability) and not to an interface, as the amplitude of the original seismic data. This characteristic transforms seismic data into layers model, facilitating petrophysical and geological interpretation.

In this work, acoustic impedance was calculated by deterministic seismic inversion technique, which transforms reflectivity into impedance, with information from 17 boreholes and time window of 1.050m/s, between defined horizons. As a recursive inversion, constrained sparse-spike optimizer proceeding was applied, minimizing the objective function. For this purpose, we used Macaé and Quissamã horizons, and markers determined by GR, NPHI and RHOB information. Furthermore, the velocity model was constructed by surface time-depth model (STDm).

The Hölder exponent is also used in this work. It seeks to characterize singularities of the signal, and it is used in lithological classification based on different behavior of well log data for different lithology.

All this data was combined and analyzed by SOM. The method consists of two layers or maps: the input represented by the attributes connected to the second layer, an elastic mesh or self-organizing map, which consists of interconnected neurons.

In this processing, each neuron represents a pattern and they have topological structure, i.e., the farther the neurons are, the more different are the patterns they characterize.

After training, the data is divided into k groups. However, as the algorithm is not supervised, the selected groups can be interpreted by a specialist, by average values or by core data information, if it is available.

SOM is applied in two steps. In the first one, classification of well log data was done with acoustic impedance values, which showed 89.75% of correlation with cutting data. This classification was called variable V7, and it was used as part of training dataset for other created scenarios.

In this classification, the algorithm did not recognize sandstone, because of the lower number

of samples (0.024%) and the shale facies was mistaken for marl facies, due to its influence, which has more data and represents the class with highest percentage of matching. Although cutting data has errors related to depth and mixed lithology, this information was sufficient to identify the clusters obtained by SOM analysis.

In the second step of classification, nine different scenarios were created and the results of SOM classification were compared to core data. The scenarios constitute combinations of well log data, derivative well logs, acoustic impedance, Hölder exponents applied on all or specific well log, and variable V7.

Among all created scenarios the most correlated to core data was the classification of the basic suite of well log data, acoustic impedance and the variable V7,

with 77.24% of correlation. The dataset was clustered into 4 described core facies, in which non-reservoir and reservoir facies represent the highest correlation facies.

Cement and possible reservoir facies show lower hit rate, maybe because of the lots lithofacies that they represent, i.e., they do not have a unique pattern, confounding the algorithm and producing the smaller hit.

Although, less correlated than the first scenario, the hit rate, 77% is still relevant, so this method can be used as an alternative way to characterize facies, in a typical problem, in which information about core data is rare. In this work we show that integration of different data can improve the automatic classification. The additional information improves the hit rate in 16%, minimizing risks in facies estimation, despite uncertainties intrinsic to cutting data.

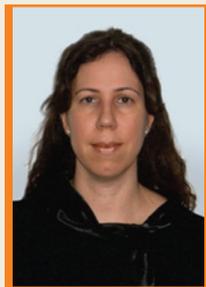
autores



Michelle Chaves Kuroda
Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

mckuroda@ige.unicamp.br

Michelle Chaves Kuroda graduou-se em Matemática pela Universidade Estadual de Campinas (Unicamp) em 2007, concluiu o mestrado em 2012 e iniciou o doutorado no mesmo ano em Geociências no Departamento de Geologia e Recursos Naturais (DGRN). Desde 2010 colabora com projetos de pesquisa financiados pela Petrobras, desenvolvendo análise de dados geofísicos com redes neurais artificiais para caracterização de eletrofácies, multiatributos e inversão sísmica.



Juliana Finoto Bueno
Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

juliana.bueno@ige.unicamp.br

Juliana Finoto Bueno graduou-se em Geologia pela Universidade Estadual de Campinas (Unicamp) em 2003. Pela mesma Universidade obteve o doutorado em Geociências em 2008. Desde 2009 trabalha como pesquisadora para a Rede Temática de “Caracterização e modelagem de reservatórios” em um convênio entre a Unicamp e a Petrobras. Desenvolve pesquisas nas áreas de Modelagem Geológica, Petrofísica e análise de incertezas geológicas na Caracterização de Reservatórios.



Alexandre Campanhe Vidal
Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

vidal@ige.unicamp.br

Alexandre Campanhe Vidal possui graduação em Geologia pelo Instituto de Geociências da Universidade de São Paulo (USP) em 1993, mestrado em Geociências pela Universidade Estadual de Campinas (Unicamp) em 1997, na área de Geoengenharia de Reservatórios. Doutorado em Geologia Regional pela Universidade Estadual Paulista Júlio de Mesquita Filho (Unesp) em 2002. É professor assistente Doutor (MS-3.2) da Universidade Estadual de Campinas (Unicamp). Bolsista de Produtividade em Pesquisa do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Nível 2. Desenvolve pesquisas na área de Caracterização Geológica de Reservatórios.



Bruno César Zanardo Honório
Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

brunohonorio@gmail.com

Bruno César Zanardo Honório formado em Física em 2008 e Mestre em Ciências e Engenharia de Petróleo em 2011, ambos pela Universidade Estadual de Campinas (Unicamp). Cursa doutorado em Geociências e é colaborador do grupo de Modelagem Geológica de Reservatórios (MGR) no Centro de Estudos de Petróleo (Cepetro) na Unicamp. Sua pesquisa está relacionada à análise tempo-frequência, métodos estatísticos, atenuação de ruídos e atributos geofísicos.



Emilson Pereira Leite

Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

emilson@ige.unicamp.br

Emilson Pereira Leite é professor Doutor MS-3.1 do Departamento de Geologia e Recursos Naturais (DGRN) do Instituto de Geociências da Unicamp. Bolsista de Produtividade em Pesquisa do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Nível 2. Graduado em Geofísica em 1997, Mestre em Geofísica em 2000 e Doutor em Geofísica em 2005 ambos pela Universidade de São Paulo (USP), tendo realizado estágio no Departamento de Ciências Espaciais e da Terra e Engenharia da Universidade de York no Canadá. Tem experiência na área de Geofísica e atua principalmente nos seguintes temas: inversão de dados geofísicos; estudos geofísicos de estruturas de impacto; integração de dados geofísicos, de sensores remotos e geológicos aplicada à exploração mineral e de hidrocarbonetos.



Rodrigo Duarte Drummond

Universidade Estadual de Campinas (Unicamp)
Instituto de Geociências
Departamento de Geologia e Recursos Naturais

rdrummond@ige.unicamp.br

Rodrigo Duarte Drummond formou-se em Matemática Aplicada e Computacional pela Universidade Estadual de Campinas (Unicamp), em 1995. Nessa mesma universidade, obteve o título de Doutor em Genética e Biologia Molecular, com ênfase em Bioinformática em 2007. Trabalha como pesquisador no Centro de Estudos do Petróleo (Cepetro) da Unicamp. Tem experiência em análise computacional de dados, com ênfase em dados de expressão gênica e dados geofísicos.