



MAPEAMENTO DE FÁCIES SÍSMICAS UTILIZANDO UM ALGORITMO DE REDE NEURAL APLICADO À CARACTERIZAÇÃO DE RESERVATÓRIOS DE PETRÓLEO

Jonas Q. de Castro

PETROBRAS, E&P-BC/GERET/GEREV-C

R. Elias Agostinho, 665 - Macaé, RJ. - 27913-350

César A. Ushirobira

PETROBRAS, E&P-BC/GERET/GECAR

R. Elias Agostinho, 665 - Macaé, RJ. - 27913-350

***Resumo.** O mapeamento de fácies sísmicas utilizando o algoritmo de redes neurais baseado nos Mapas Auto-organizáveis de Kohonen, disponibilizado pela CGG-PetroSystems, permitiu uma melhor compreensão das relações espaciais entre os reservatórios que constituem os dois principais blocos produtores de um campo de petróleo, situado na porção central da Bacia de Campos, Rio de Janeiro, Brasil. Além da rápida implementação, o programa utilizado permitiu a observação de pequenas descontinuidades ou barreiras ao fluxo, muito importantes para a correta construção do modelo dinâmico do campo, que durante o mapeamento convencional não puderam ser percebidas. Os resultados alcançados confirmaram as informações provenientes dos testes de produção, e legitimaram o modelo geológico proposto.*

***Palavras-chave:** Fácies sísmicas, Reservatórios, Redes neural*

1. INTRODUÇÃO

Este trabalho tem como objetivo apresentar os resultados do estudo de caracterização dos reservatórios de um campo de petróleo da Bacia de Campos, obtidos durante a etapa de reinterpretação sísmica de detalhe, na qual foi empregado o programa STRATAMAGIC (fundamentado nas redes neurais) da CGG-PetroSystems[®] para o mapeamento das fácies sísmicas presentes na área estudada.

Porém, primeiramente, serão apresentadas algumas definições básicas necessárias à compreensão das redes neurais, e às principais características da técnica de mapeamento empregada pelo programa acima mencionado, discutindo os seguintes tópicos: a Dinâmica Competitiva e o Aprendizado Competitivo. Posteriormente, discutiremos as principais características dos Mapas Auto-organizáveis de Kohonen (Self-Organizing Features Maps), que é a base do algoritmo de mapeamento de fácies sísmicas propriamente dito.

Os resultados alcançados com a metodologia empregada evidenciam que a associação das litofácies presentes nos poços perfurados com a distribuição espacial das fácies sísmicas mapeadas foi decisiva para definir, com maior segurança e precisão, os limites dos novos compartimentos do campo, sugeridos pelos dados de pressão obtidos a partir dos testes de produção.

2. DEFINIÇÕES E ESTRUTURA BÁSICA DAS REDES NEURAIS.

Redes Neurais são conjuntos de processadores simples interconectados, denominados unidades ou nós, cuja funcionalidade assemelha-se aos neurônios animais. A habilidade de processamento das redes é armazenada nos elementos conectores dos processadores (ponderadores), obtidos, por exemplo, por um processo de adaptação, ou aprendido, a partir de um conjunto de padrões de treinamento (Figura 1).




Figura 1 - Neurônio Artificial esquemático (P = ponderadores; T = Threshold; Σ = Integração dos inputs).

O funcionamento das redes baseia-se numa analogia com os neurônios naturais, os quais se comunicam a partir de sinais elétricos (pulsos) gerados na membrana celular, causados por pequenas variações de voltagens. As conexões entre os neurônios são intermediadas por junções eletroquímicas, chamadas sinapses, que localizam-se em terminações da célula nervosa, denominadas dendritos. Os sinais provenientes de outros neurônios são integrados no corpo da célula receptora, e se excederem a um limite específico (*threshold*) o neurônio é excitado, ou seja, gera um impulso-resposta que é transmitido a outros neurônios via axônio.

A habilidade de processamento de um neurônio reside no tipo (inibidora ou excitadora) e na força das conexões sinápticas com outros neurônios. O tipo de construção e operação apresentado para os neurônios naturais são aqueles que espera-se de uma rede neural artificial, que por isso é denominada, algumas vezes, conectivista.

Nos equivalentes artificiais, as sinapses são modeladas por ponderadores que atuam sobre os sinais de entrada antes de enviá-los ao “corpo da célula”, onde somados fornecem a ativação do nó. Este tipo de unidade básica de processamento é denominada TLU (*threshold logic unit*), porque a ativação é comparada a um valor de corte (threshold), e sendo superior a ao último a unidade de processamento produz, geralmente, um valor numérico de saída igual a 1, caso contrário, igual a zero.

Uma revisão mais aprofundada dos princípios e aplicações dos algoritmos neurais não compreende o escopo deste trabalho; contudo, a literatura sobre o assunto é vasta, e servem como referência as publicações de Hertz et alli (1991) e Gurney (1997), entre outros.

3. FUNDAMENTOS TEÓRICOS DAS REDES NEURAIS AUTO-ORGANIZÁVEIS

Uma das principais habilidades das redes neurais é a capacidade para identificar agrupamentos (clusters) de padrões similares num conjunto de dados quaisquer (Gurney, 1997). Na Figura 2a, percebemos a existência de agrupamentos. Se uma rede, sem qualquer informação *a priori*, pode associar a cada um destes agrupamentos um nó específico, diz-se que a rede é auto-organizável e seu treinamento não supervisionado.




Figura 2 – Agrupamentos observados no espaço amostral (a); Energia de Ativação (S) de cada nó, antes e após o treinamento (b). (Adaptado de Gurney, 1997)

O desenvolvimento de tal habilidade por um algoritmo de rede neural exige o reconhecimento dos nós mais sensíveis a cada um dos padrões que, por ventura, existam no universo de dados amostrais. Para tanto, devemos suprir à rede alguns recursos extras, os quais possibilitem que esta pesquisa ocorra internamente à ela.

3.1 A Dinâmica Competitiva

Uma técnica útil ao propósito acima referido, baseia-se na construção da rede neural sob a ótica da Dinâmica Competitiva; neste tipo de construção o nó, cuja ativação inicial, estimulada por um dado (input) específico é a mais acentuada, tem sua ativação amplificada, enquanto que os demais nós da rede, para esse mesmo dado, têm suas ativações inibidas ou enfraquecidas. Neste caso, diz-se que a rede desenvolve-se via competição, e que o nó mais sensível a determinado dado externo – e que portanto possui uma vantagem inicial sobre os demais nós da rede - ganha a competição, capturando toda a ativação da rede para si mesmo. (Figura 2b)

Nas redes que desenvolvem-se através da dinâmica competitiva, todas as unidades de processamento (nós) recebem simultaneamente o mesmo conjunto de dados de entrada. Além disso, existem conexões intra-camadas (Figura 3a), onde cada nó está ligado a si mesmo através de uma conexão excitatória, e aos demais via conexões inibidoras. Isto explica porque o nó com maior ativação inicial tem sua resposta reforçada ao mesmo tempo que inibe as respostas dos outros nós da sua camada.

3.2 Aprendizado Competitivo

Consideremos um subconjunto de treinamento, definido a partir dos dados amostrais¹, onde os vetores de dados \mathbf{x} têm o mesmo comprimento unitário, ou seja $\|\mathbf{x}\|=1$, para todo \mathbf{x} . Desta forma, no caso bidimensional estes vetores podem ser representados circunscritos por círculo unitário (Figura 3b).

¹ Nesta discussão devemos pensar a representação dos dados na forma de vetores (\mathbf{x}) no espaço amostral; da mesma forma os ponderadores (\mathbf{w}) intrínsecos aos nós ou unidades de processamento das camadas da rede.

Estando uma camada de rede neural competitiva -- cujos vetores ponderadores (\mathbf{w}) unitários também podem ser representados no círculo unitário da Figura 2 -- conectada a uma camada externa para a entrada de dados (\mathbf{x}), então o que se espera dessa rede é que cada nó que compõe a camada responda de maneira acentuada a um conjunto de vetores de dados que represente um agrupamento específico no espaço amostral. Assim, quando um vetor \mathbf{x} é apresentado à rede, deve existir apenas um nó, com seu vetor \mathbf{w} de ponderadores, que responda de forma acentuada a \mathbf{x} .




Figura 3 - (a) Esquema de uma camada competitiva exibindo as conexões laterais inibidoras (-) e uma auto-conexão excitatória (+) de um único nó; Representação dos vetores ponderadores e de dados no círculo unitário, antes (b) e após (c) o treinamento. (Adaptado de Gurney, 1997)

Para que isto ocorra devemos entender a relação que existe entre um vetor de ponderadores \mathbf{w} e um vetor de dados \mathbf{x} , quando um nó responde fortemente a \mathbf{x} . Com este intuito, devemos tratar a resposta S (a ativação) dos nós como sendo o valor do produto interno dado por $\mathbf{x} \cdot \mathbf{w}$, que do ponto de vista geométrico, será maior quanto mais alinhados estiverem os vetores \mathbf{x} e \mathbf{w} . Isto está claramente expresso na Equação 1,

$$S = \|\mathbf{x}\| \cdot \|\mathbf{w}\| \cdot \cos \theta \quad (1)$$

onde θ é o ângulo entre \mathbf{x} e \mathbf{w} .

A rede ideal deverá, após a etapa de treinamento, ter cada um dos seus vetores de ponderação alinhado a um conjunto de vetores \mathbf{x} , representativos de um dos agrupamentos existentes no espaço amostral de treinamento (Figura 3c). Isto pode ser conseguido pela “rotação” de cada vetor \mathbf{w} , de forma que estes sejam progressivamente alinhados aos vetores \mathbf{x} , que inicialmente encontravam-se mais próximos.

Tal tarefa pode ser realizada da seguinte forma: apresenta-se iterativamente à rede os vetores \mathbf{x} , ajustando-se a seguir o vetor \mathbf{w} do nó cuja ativação inicial é a mais acentuada. Na prática, se denotarmos o nó “vencedor” com o índice k , então seu vetor ponderador \mathbf{w}_k poderá ser rotacionado em direção à \mathbf{x} pela adição de uma fração da diferença $(\mathbf{x} - \mathbf{w}_k)$. Isto define a regra de treinamento para qualquer nó arbitrário j :

$$\begin{aligned} \Delta \mathbf{w}_j &= \alpha(\mathbf{x} - \mathbf{w}_j) : j = k \\ \Delta \mathbf{w}_j &= 0 : j \neq k \end{aligned}$$

3.3 Mapas de Kohonen

Além da identificação de agrupamentos num conjunto de dados, existe um nível adicional de organização que uma rede competitiva pode atingir. Isto ocorre quando nós que são fisicamente adjacentes na rede, respondem a padrões que também são adjacentes, em algum sentido, no espaço-padrão do dados amostrais.

Este conceito de proximidade conduz a idéia de topografia ou mapa da própria rede, onde esse mapa representaria alguma característica do espaço amostral.

Grande parte do desenvolvimento necessário para o treinamento de uma rede neural utilizando o princípio de mapeamento deve-se a Kohonen (1982, 1984 e 1990), que definiu este princípio sob a ótica da engenharia, e expressou suas bases teóricas e desenvolvimentos posteriores (*in* Gurney, 1997).

Uma discussão mais aprofundada do algoritmo proposto por Kohonen pode ser encontrada em Gurney (1997) e Pereira (1995), ou nos trabalhos acima referidos. Aqui apresentaremos apenas os principais aspectos que definem esta técnica:

1. A arquitetura da rede ainda consiste num conjunto de dados de entrada completamente conectados à camada auto-organizável; contudo, não existem mais conexões laterais;
2. Para a definição do mapa sobre a rede é necessário que o treinamento se dê sobre uma região centrada no nó de maior atividade; assim, introduz-se o conceito de “vizinhança”, contrário ao princípio do “vencedor” único apresentado nas seções anteriores;
3. Durante a fase de treinamento, primeiro determina-se qual o nó de maior atividade, empregando-se como critério de escolha o valor mínimo da diferença entre $\|\mathbf{x}\|$ e $\|\mathbf{w}_k\|$ ao invés do produto interno destes vetores; desta forma, a etapa de normalização não é mais necessária.
4. Tendo determinado o nó cuja a ativação é máxima, este e os demais nós presentes numa vizinhança de dimensão pré-determinada, são treinados segundo a equação abaixo:

$$\begin{aligned} \Delta \mathbf{w}_j &= \alpha(\mathbf{x} - \mathbf{w}_j) : \text{se } j \in V_K \\ \Delta \mathbf{w}_j &= 0 : \text{se } j \notin V_K \end{aligned}$$

- V_K é a vizinhança;
5. Reduz-se ligeiramente a taxa de aprendizado (α) e após um número específico de iterações a vizinhança é também diminuída.

Como dito anteriormente, o treinamento sobre uma região, e não apenas do nó “vencedor”, impõe o mapeamento da rede. Iniciando o treinamento com uma vizinhança suficientemente grande, garante-se um ordenamento global, o que impede partes distintas da rede responderem a um mesmo padrão presente no espaço amostral.

Quando uma solução estável é finalmente encontrada, os vetores de ponderadores associados a cada um dos agrupamentos representam, de alguma forma, vetores médios ou típicos dos agrupamentos, já que eles foram “rotacionados” na direção dos agrupamentos durante o treinamento. Assim, podemos tomar estes vetores como arquétipos ou modelos para os agrupamentos. O uso destes arquétipos ficará evidente durante a exposição da metodologia utilizada e dos resultados obtidos com o uso dos dados reais de um campo de petróleo, apresentados a seguir.

4. RECONHECIMENTO DAS FÁCIAS SÍSMICAS

A classificação ou agrupamento dos traços sísmicos em conjuntos de diferentes fácies sísmicas baseia-se na determinação de parâmetros ou atributos, que num espaço multidimensional permitem a distinção de agrupamentos. Tais agrupamentos, constituídos por traços morfologicamente semelhantes, representam as diferentes fácies sísmicas.

No caso específico deste estudo, o *software* empregado para a determinação das fácies sísmicas analisa através do algoritmo de redes neurais, descrito nas seções anteriores, as várias formas de traços presentes num subconjunto dos traços sísmicos 3D, denominado conjunto de treinamento, definindo aí uma série de traços sintéticos (arquétipos ou modelos) que melhor representa a diversidade de formas presentes neste subconjunto. A seguir, ordena de maneira progressiva (Figura 4) os traços sintéticos, e associa aos mesmos uma cor e um número (Addy, 1998). Cada traço representa uma fácies sísmicas pertinente, às quais os traços reais serão comparados e classificados, possibilitando a elaboração do mapa de fácies sísmicas.




Figura 4 - Série de traços sintéticos (arquétipos) representando as formas mais características presentes no sub-conjunto de treinamento (Classes 1 a 10), e traço sísmico real associado ao poço M-1.

Devido ao reduzido número de poços existentes, mas principalmente pela técnica empregado pelo *software* utilizado, realizamos uma análise não-supervisionada. Assim, primeiramente determinamos as principais fácies sísmicas existentes no volume sísmico de interesse e, posteriormente, avaliamos seus possíveis significados geológicos.

5. ESTUDO DE CASO

5.1 O campo e o Problema

O campo estudado situa-se na porção central da bacia de Campos em batimetria de 140 a 360 m. No atual estágio de desenvolvimento existem 9 poços exploratórios perfurados, sendo a produção diária de óleo igual a 1385,0 m³ e o volume de óleo *in place* original superior a 13,5x10⁶ m³.

Naumann et alli (1994) identificaram 4 seqüências deposicionais na área do campo, cujas idades variam desde Paleoceno Inferior (N-305,N-307) até Eoceno Médio (N-440, N447, N-450). As principais litofácies reconhecidas nos testemunhos são: Arenito fino a médio com estratificação cruzada (R5), Arenitos fino a médio (R2) e médio a grosso (R3) maciços, Arenitos siltico (A1) e fino (R1) bioturbados, além de arenitos cimentados (R0) (Albertão e Carneiro, 1997). Os reservatórios do campo são interpretados como depósitos de

correntes de turbidez de densidade alta a baixa, localmente retrabalhados por correntes de fundo.

O zoneamento estratigráfico em vigor foi determinado por Braga et alli (1994), o qual estabeleceu duas zonas estratigráficas para o campo, denominadas: Zona Enchova e Zona Barracuda.

O campo encontra-se compartimentado em três blocos de produção (Bloco I, II e III). A princípio os Blocos II e III eram tratados como um único bloco de produção, ou sistema hidráulico, que foi compartimentado exclusivamente com base nos dados de pressão provenientes de teste de produção realizados durante a completção de poços já existentes.

Os limites entre estes novos blocos não eram perfeitamente conhecidos, tendo sido estabelecidos de forma arbitrária, o que implicava na imprecisão dos cálculos dos volumes de óleo *in place* e recuperável. Um novo estudo para revisar tanto o arcabouço estrutural quanto o estratigráfico fazia-se necessário; o principal objetivo desta revisão era estabelecer, com a maior precisão possível, o limite entre os Blocos II e III, bem como a real extensão areal destes blocos.

Durante a reinterpretação sísmica da área, foi efetuado o mapeamento das fácies sísmicas existentes (Figura 5), esperando que a distribuição dos diversos reservatórios pudesse ser parcialmente explicada pela distribuição areal das mesmas. Assim sendo, o mapeamento das fácies sísmicas foi utilizado como ferramenta auxiliar à interpretação sísmica, a fim de prover, principalmente, informações qualitativas sobre os limites entre os Blocos II e III.




Figura 5 - Mapa de Fácies sísmicas na evidenciando regiões com domínios bem marcados, os quais estão indicando a compartimentação mista do campo: Bloco II (Poços RS2, RS3 e M2) e Bloco III (Poços: RS1 e M1); a linha tracejada sugere o limite estratigráfico entre os blocos.

5.2 Análise das fácies sísmicas presentes

As principais litofácies observadas nos poços existentes na região avaliada do campo, às quais pretendíamos associar as diferentes fácies sísmicas mapeadas, são apresentadas na Figura 6.

A observação destas figuras permite concluir que:

1. Nos poços pertencentes ao Bloco II, predominam as litofácies R1 e A1, perfazendo 80% e 90% da espessura total dos reservatórios nos poços RS2 e M-2 (Figuras 6a e 6c);
2. No poço RS-3, ainda no Bloco II, ocorre uma situação intermediária, onde as litofácies R2 e R3 aparecem intercaladas com as litofácies R1 e A1 (Figura 6b), com um ligeiro predomínio das fácies reservatórios de pior qualidade;
3. No poço RS-1 (Figura 6d), Bloco III, predominam as litofácies R2 e R3, que constituem cerca de 80% da espessura dos reservatórios perfurados pelo poço; estas litofácies representam as melhores fácies reservatórios do campo, sendo interpretadas como

depósitos turbidíticos canalizados, localmente retrabalhados por correntes de fundo ou maré (fácies R1, R5 e A1).

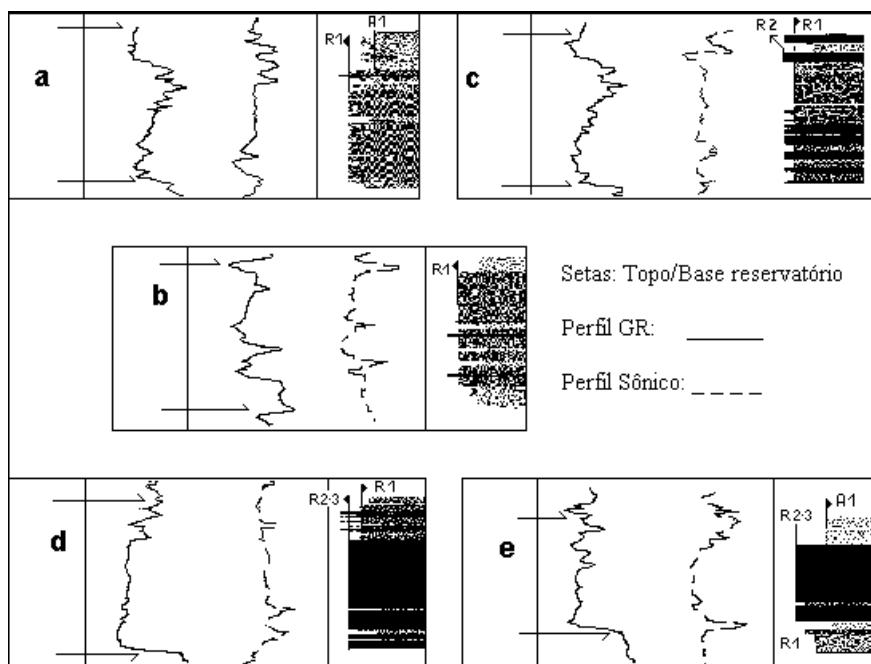


Figura 6 - Principais litofácies observadas nos poços do Bloco II (RS2 (a), RS3 (b), M2 (c)) e Bloco III (RS1 (d) e M1 (e)).

- No poço M-1 (Figura 6e), também pertencente ao Bloco III, cerca de 70% da espessura total do reservatório é constituída por duas litofácies (R2 e R3), ambas com excelentes características de produção, ocorrendo, ainda, pequenas intercalações da litofácies R0.

Pelo acima exposto, percebe-se que no Bloco III predominam as melhores fácies reservatório, enquanto que no Bloco II predominam os arenitos finos a silticos bioturbados, com características permo-porosas inferiores.

O mapa de fácies sísmicas obtido (Figura 5), balizado pelo evento previamente interpretado como sendo a envoltória dos topos dos reservatórios do campo, evidencia a diferença do conteúdo faciológico dos reservatórios existentes nos dois blocos, confirmando a observação dos poços perfurados.

Pode-se comparar, ainda, esse mapa com aqueles apresentados na Figura 7, que apresenta os refletores dos topos dos reservatórios dos Blocos II e III mapeados pelo método convencional, ou seja, rastreando horizontes nas seções de amplitude. Na Figura 6 observa-se facilmente a coincidência entre a distribuição areal dos padrões de fácies sísmicas e as ocorrências dos reservatórios mapeados nas seções tradicionais, reforçando a tese da separação entre os dois blocos.

Cabe ressaltar que os resultados apresentados, os quais confirmaram a separação entre os blocos evidenciada pelos dados de produção, foram obtidos a partir de metodologias completamente distintas, avalizando as interpretações geológica e geofísica propostas.

O mapa de fácies sísmicas também auxiliou no refinamento dos eventos mapeados, possibilitando uma melhor definição da distribuição espacial de cada um desses eventos. E indicou, ainda, a presença de possíveis pequenas falhas ou barreiras ao fluxo, informações importantes para a construção de um modelo de fluxo mais realista.

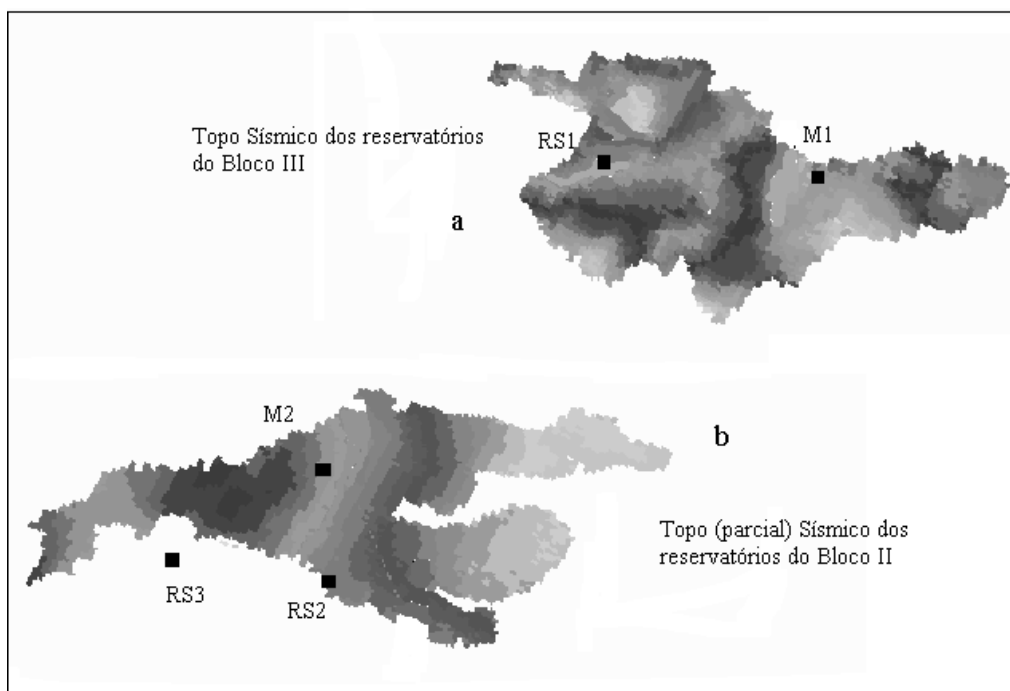


Figura 7 - Topos Sísmicos dos reservatórios dos Blocos II e III do campo: Notar a coincidência entre as áreas mapeadas e os domínios de fácies sísmicas exibidos na Figura 5, que associam-se aos poços M2 e RS1/M1, principalmente.

6. CONSIDERAÇÕES FINAIS

O emprego da análise de fácies sísmicas no campo estudado confirmou a separação entre os dois principais blocos de produção, sugerida pelos dados de pressão. Além disso, permitiu uma melhor definição dos limites das ocorrências dos arenitos que compõem os reservatórios dos blocos, auxiliando o detalhamento sísmico. O STRATAMAGIC[®] constituiu-se numa poderosa e rápida ferramenta para a interpretação sísmica de detalhe, capaz de auxiliar o refinamento do modelo sísmico interpretado.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- Addy, F.K., 1998, Neural net generated seismic facies map and its application in various geologic environments: examples from South Texas Basin, PTS 10th Anniversary User Club, Houston, Texas.
- Albertão, G.A. & Carneiro, S.R.R., 1997, Estudo de correlação rocha-perfil nos reservatórios dos campos de Corvina, Malhado, Congro, Salema e Bijupirá, Relatório Interno da Petrobras, Rio de Janeiro.
- Braga, M.S. et alli, 1994 - Revisão Estratigráfica do Campo de Malhado, Relatório Interno da Petrobras, Rio de Janeiro.
- Gurney, K., 1997, Introduction to Neural Networks, UCL Press, London.
- Hertz, J. et alli, 1991 – Introduction to the Theory of Neural Computation, Addison-Wesley Publishing Company.
- Kohonen, T., 1982, Self-organized formation of topologically correct feature maps, Biological Cybernetics, vol. 43, pp. 59-69.
- Kohonen, T., 1984, Self-organization and associative memory, Springer-Verlag, Berlin.

- Kohonen, T., 1990, The self-organizing map, Proceedings of IEEE, vol. 78, n. 9, pp: 1464-1480.
- Naumann, M.P. et alli, 1994, Processos deposicionais relacionados aos turbiditos do Eoterciário dos campos de Corvina, Malhado, Leste de Malhado, Salema e Bijupirá - Bacia de Campos, II Seminário de Interpretação Exploratória, Rio de Janeiro, pp. 98-102.
- Pereira, P.R.S., 1995, Análise de agrupamentos por Mapas de Kohonen, Tese de Mestrado, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

Title: A Neural Network Approach for Seismic Facies Mapping applied to Reservoir Characterization.

Jonas Q. de Castro

PETROBRAS, E&P-BC/GERET/GEREV-C

Av. Elias Agostinho, 665 - Macaé, RJ. - 27913-350

César A. Ushirobira

PETROBRAS, E&P-BC/GERET/GECAR

Av. Elias Agostinho, 665 - Macaé, RJ. - 27913-350

Abstract: *The seismic facies mapping using a neural network approach based on the Kohonen's Self-Organizing Features Maps, supplied by CGG-PetroSystems, has improved the understanding of the spatial relationship between two producer reservoirs of an offshore Campos Basin's oil field in Rio de Janeiro, Brazil. The seismic facies map showed subtle discontinuities which were not observed during the conventional amplitude mapping. Such observed discontinuities are special worthy to build a more accurate dynamic model. The map of seismic facies confirmed the data from producer well tests and contributed to a more realistic geological modeling.*

Key-words: *Seismic facies, Reservoirs, Neural nets*