

### 3 Análise de Fácies Sísmicas

Os modelos geológicos dos reservatórios são formados a partir de estimativas de características específicas das rochas ou sedimentos. Estimativas das propriedades das rochas, tais como porosidade, permeabilidade, tipo do fluido, litologia e outras propriedades dos reservatórios são fundamentais para a exploração, desenvolvimento e produção de campos de petróleo. Assim, a busca por modelos mais exatos e confiáveis é uma questão de grande impacto para as companhias que exploram petróleo, pois pequenos erros quantitativos no dimensionamento dos reservatórios podem representar grandes perdas, ou ganhos, econômicos.

Toda a sorte de informação é válida para a construção dos modelos de reservatório. Uma das mais importantes é a proveniente de poços perfurados. Informações como perfis, amostras estratigráficas e dados de produção são bastante precisas. Entretanto, são pontuais e não refletem o comportamento do reservatório como um todo, além de não estarem disponíveis na fase inicial de exploração. Modelos construídos utilizando somente dados de poço são extrapolações de propriedades pontuais para a área do reservatório. Informações de poços são muito importantes para a calibração de modelos de reservatório gerados a partir de informações sísmicas.

Ao contrário dos dados de poços, os dados sísmicos 3D abrangem grandes áreas e embora não tenham a mesma resolução, assumindo que mudanças na litologia, nas propriedades das rochas e/ou dos fluidos, afetam os traços sísmicos com respeito a amplitude, forma e coerência lateral, pode-se considerar que a análise das variações dos atributos sísmicos na região do reservatório analisado, possa ser utilizada como ferramenta para a construção de modelos de reservatório. A descrição e interpretação de parâmetros extraídos das reflexões sísmicas, incluindo geometria, continuidade, amplitude, frequência e velocidade intervalar é chamada de análise de fácies sísmicas (Mitchum, 1977).

A análise de fácies sísmicas é realizada através do emprego de técnicas de reconhecimento de padrões, onde através da combinação adequada de

atributos sísmicos, busca-se a identificação de características geológicas dos reservatórios. Dentre as técnicas usadas, destacam-se as redes neurais.

Independente da técnica de modelagem adotada, para um eficaz reconhecimento de padrões sísmicos, é bastante importante a seleção correta dos atributos sísmicos.

### **3.1.Métodos Utilizados para a análise de fácies sísmicas.**

A análise de fácies sísmicas não é uma tarefa simples, tampouco determinística. Pois, não existe, ainda, consenso sobre uma forma padrão para análise, levando os interpretes a diversificar a forma de análise.

A análise de fácies sísmica pode ser não-supervisionada ou supervisionada.

Diz-se que a análise de fácies sísmica é não-supervisionada, sempre que as informações sobre a geologia da região forem incompletas ou inexistentes, ou seja, no período de exploração ou quando a área analisada ainda não tiver sido suficientemente explorada através da perfuração de poços.

A análise de fácies sísmica será supervisionada quando existirem dados suficientes da região para se depurar a análise.

Independente da análise de fácies sísmica ser supervisionada ou não, geralmente, a sua realização se dá de acordo com o seguinte fluxo de trabalho (Johann, 2000):

- a) Segmentação espacial e temporal dos dados sísmicos 3D com orientação geológica;
- b) Seleção dos atributos sísmicos que serão utilizados;
- c) Escolha do número de classes, fácies ou padrões, e o número de iterações que serão utilizados pelo algoritmo;
- d) Treinamento e classificação dos atributos selecionados utilizando alguma ferramenta estatística ou redes neurais;
- e) Construção e Interpretação dos mapas de fácies sísmicas.

Na fase a) do fluxo descrito, a segmentação dos dados é realizada através da interpretação sísmica dos horizontes que revelam a área de interesse no volume de dados 3D. A figura 20 ilustra o resultado do processo de interpretação sísmica do topo e base do reservatório de um campo de petróleo.

Normalmente, as segmentações temporal e espacial devem ser realizadas cuidadosamente, pois quaisquer erros de interpretação podem levar a resultados de fácies muito ruidosos.

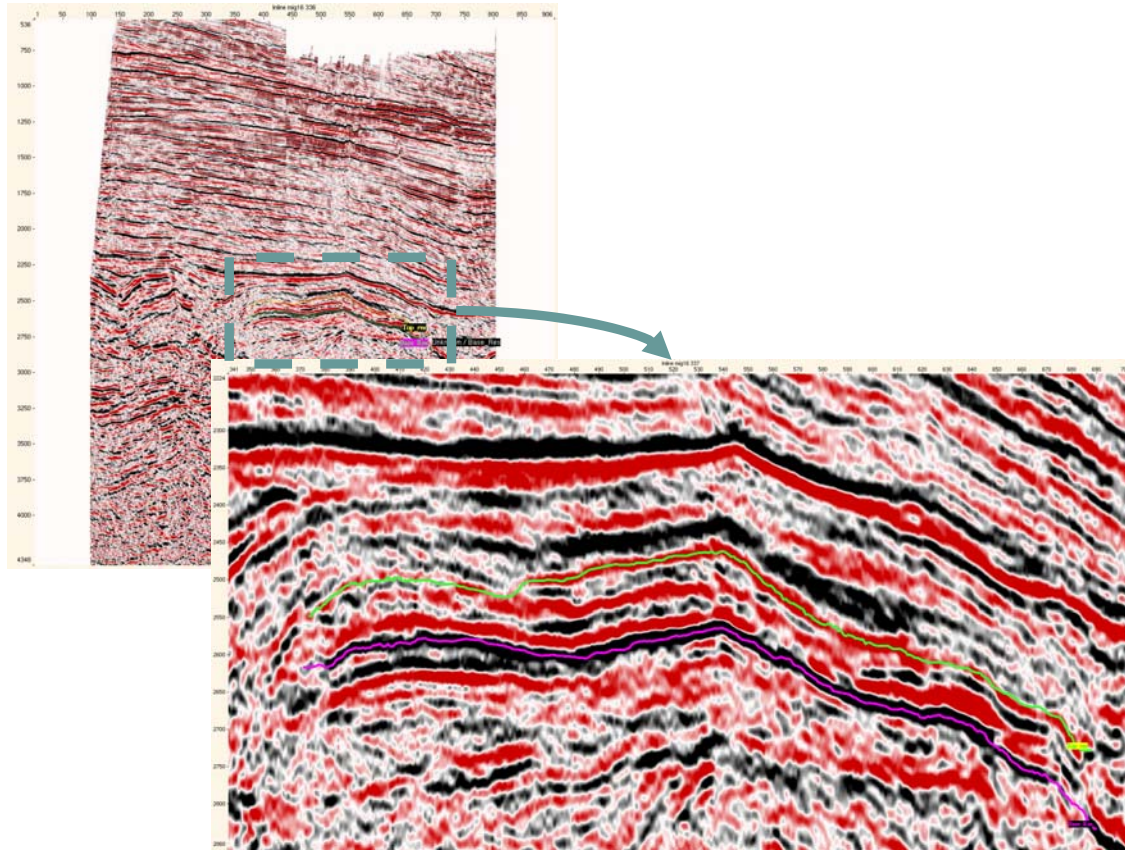


Figura 20: Interpretação do topo e da base de um reservatório de petróleo

Na fase *b)*, os atributos sísmicos que melhor representem aspectos geologicamente importantes da região devem ser selecionados. Tal tarefa é bastante empírica. Eventuais correlações estatísticas devem ser verificadas entre os atributos sísmicos escolhidos, evitando a redundância de informação. A figura 21 ilustra alguns atributos sísmicos obtidos para o mesmo reservatório ilustrado na figura 20:

- frequência instantânea integrada entre topo e base do reservatório;
- amplitude sísmica integrada entre topo e base do reservatório;
- magnitude integrada entre topo e base do reservatório;
- co-seno da fase integrado entre topo e base do reservatório;
- amplitude integrada entre topo e base do reservatório;
- polaridade aparente integrada entre topo e base do reservatório;

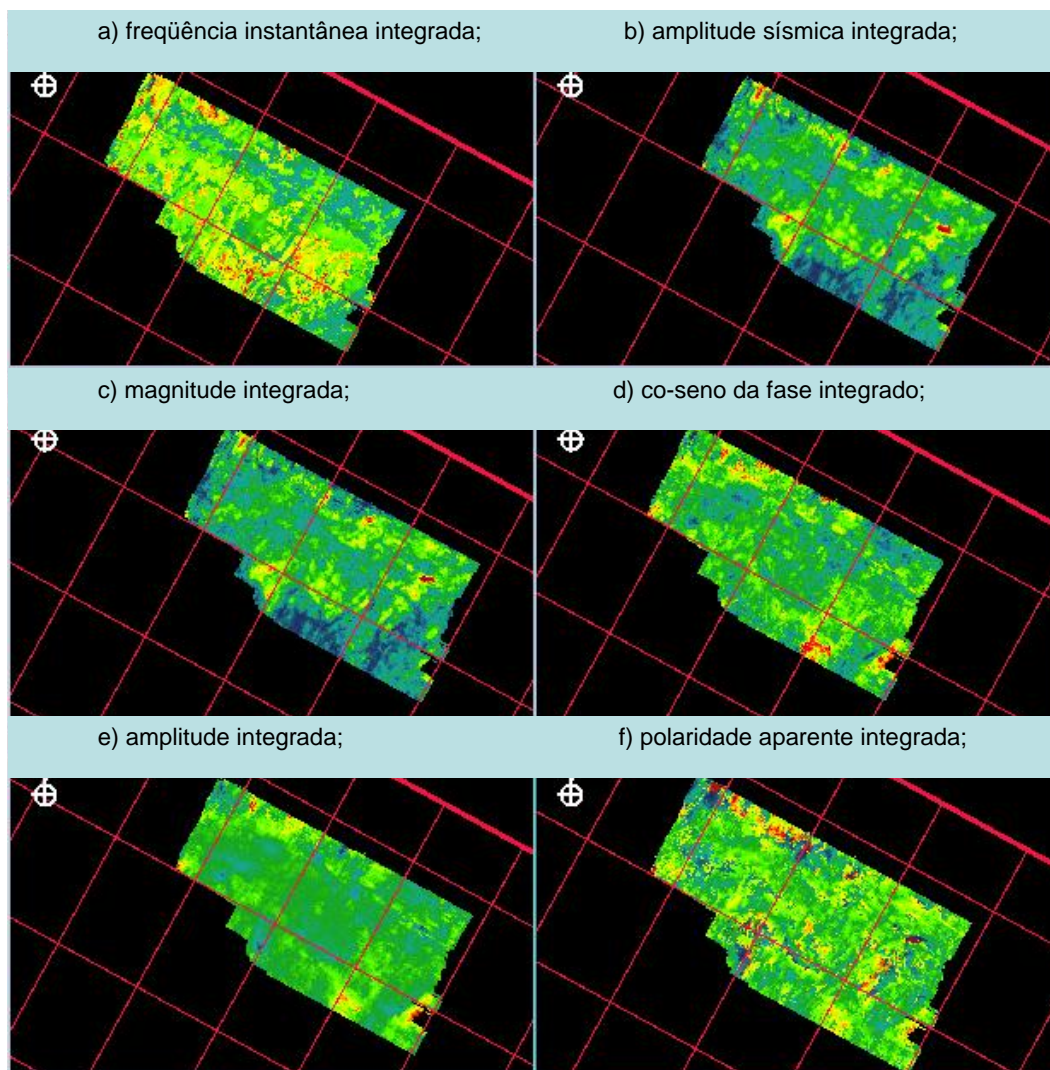


Figura 21: Atributos típicos integrados entre topo e base do reservatório a) Frequência instantânea integrada; b) Amplitude sísmica integrada; c) Magnitude integrada; d) Co-seno da fase integrado; e) Amplitude integrada; f) Polaridade aparente integrada. (Os atributos foram gerados com o programa Charisma da Schumberger).

Na fase c), o número de fácies sísmicas é arbitrado de forma empírica ou através de algum conhecimento da região quando existente.

A escolha do algoritmo usado para a classificação dos atributos sísmicos é função do conhecimento geológico da região em análise. Quando a análise for não supervisionada, utilizam-se algoritmos que busquem a clusterização ou agrupamentos dos dados que tenham características em comum. Os algoritmos mais utilizados pelos programas comerciais são o K-means (Duda et al., 2001) e o de Aprendizado Competitivo (Gurney, 1997).

Quando a análise é supervisionada, utilizam-se algoritmos estatísticos tradicionais como o Discriminante de Fisher (Duda et al., 2001) ou redes neurais como o algoritmo de retro-propagação (Haykin, 1999).

Definido o melhor algoritmo para o caso em questão, na fase *d*), é realizado o treinamento e a classificação das fácies sísmicas, que são devidamente analisadas na fase seguinte.

O resultado da análise de fácies sísmicas é chamado de mapa de fácies sísmicas. Através deste mapa, pode-se avaliar características em comum existentes na região analisada. Associando informações de poços é possível calibrar o mapa para a característica geológica desejada. A figura 22 ilustra um exemplo de um mapa de fácies sísmica, não-supervisionado, com quatro classes. Utilizou-se o algoritmo de aprendizado competitivo, tendo como entrada os atributos ilustrados na figura 21 (Seis Class, 1999).




Figura 22: Exemplo de um mapa não supervisionado com quatro diferentes fácies sísmicas obtido utilizando-se o programa Seisclass da Schulumberger.

Pode-se verificar facilmente, que apesar de sua comprovada eficácia (Johann, 1999), todo o processo descrito deve ser realizado com bastante cuidado, pois pequenos erros em qualquer etapa podem levar a resultados totalmente diferentes da realidade.

Atualmente, os Mapas Auto Organizáveis (SOM) ou mapas de Kohonen (Kohonen, 2001) vêm se tornando uma das ferramentas mais comuns para a análise não-supervisionada (Morrice et al, 1996). Entretanto, a escolha do número de classes e a melhor combinação de atributos sísmicos, normalmente, são realizadas de forma empírica pelos sistemas existentes atualmente no mercado.

### 3.2. Mapas Auto Organizáveis de Kohonen

Os mapas auto-organizáveis de Kohonen, SOM, além de produzirem uma espécie de similaridade entre os dados de entrada, são uma ferramenta efetiva para a visualização e clusterização de dados multidimensionais, convertendo relações estatísticas entre dados multidimensionais em relações geométricas simples dos pontos correspondentes no espaço de dimensão inferior, tipicamente bidimensional. Logo, o SOM pode ser interpretado como uma forma de se preservar as relações métricas e topológicas do espaço de entrada multidimensional em uma rede bidimensional, que pode ser usada como uma ferramenta de visualização, mostrando diferentes características dos dados, como sua possível estruturação em grupos.

O mapeamento realizado pelo SOM é implementado de forma similar à quantização vetorial. Assumindo que o conjunto das variáveis de entrada pode ser representado por vetores no espaço  $\mathcal{R}^n$ ,  $x=[x_1, x_2, \dots, x_n]$ , o objetivo do algoritmo é mapear o conjunto de dados de entrada em um espaço de dimensão inferior, delineado por uma estrutura geométrica, chamada de mapa auto organizável. As unidades do SOM são conectadas às suas vizinhas, formando mapas com estruturas, normalmente, hexagonais ou retangulares.

O mapeamento é realizado através de vetores protótipos que mantêm uma relação ordenada entre si. Especificamente, para cada elemento do SOM existe um vetor protótipo, que por sua vez está associado aos seus vetores protótipos vizinhos. Supondo que o mapa tenha  $P$  elementos, relacionados a estes existirão  $P$  vetores protótipos  $m_i$ ,  $m_i=[m_{i1}, \dots, m_{in}]$ ,  $i$  variando de 1 à  $P$ , onde  $n$  é a dimensão do vetor de entrada. Após, o treinamento do SOM, os vetores protótipos passam a representar o conjunto de dados de entrada.

A figura 23 ilustra a relação entre o vetor de entrada, o vetor protótipo e o SOM para um caso em particular. O número de unidades no mapa determina a sua eficácia e capacidade de generalização. Durante o treinamento, o SOM forma uma rede elástica que se adapta à “nuvem” formada pelos dados de entrada. Dados localizados próximos entre si no espaço de entrada também estarão próximos entre si no mapa formado. Desta forma, o SOM pode ser interpretado como um mapeamento do espaço de entrada em um arranjo ou reticulado bidimensional que preserva a estrutura topológica original. Tal característica o torna bastante atraente para aplicações geológicas onde as grandezas físicas são distribuídas de forma quase contínua pela natureza.

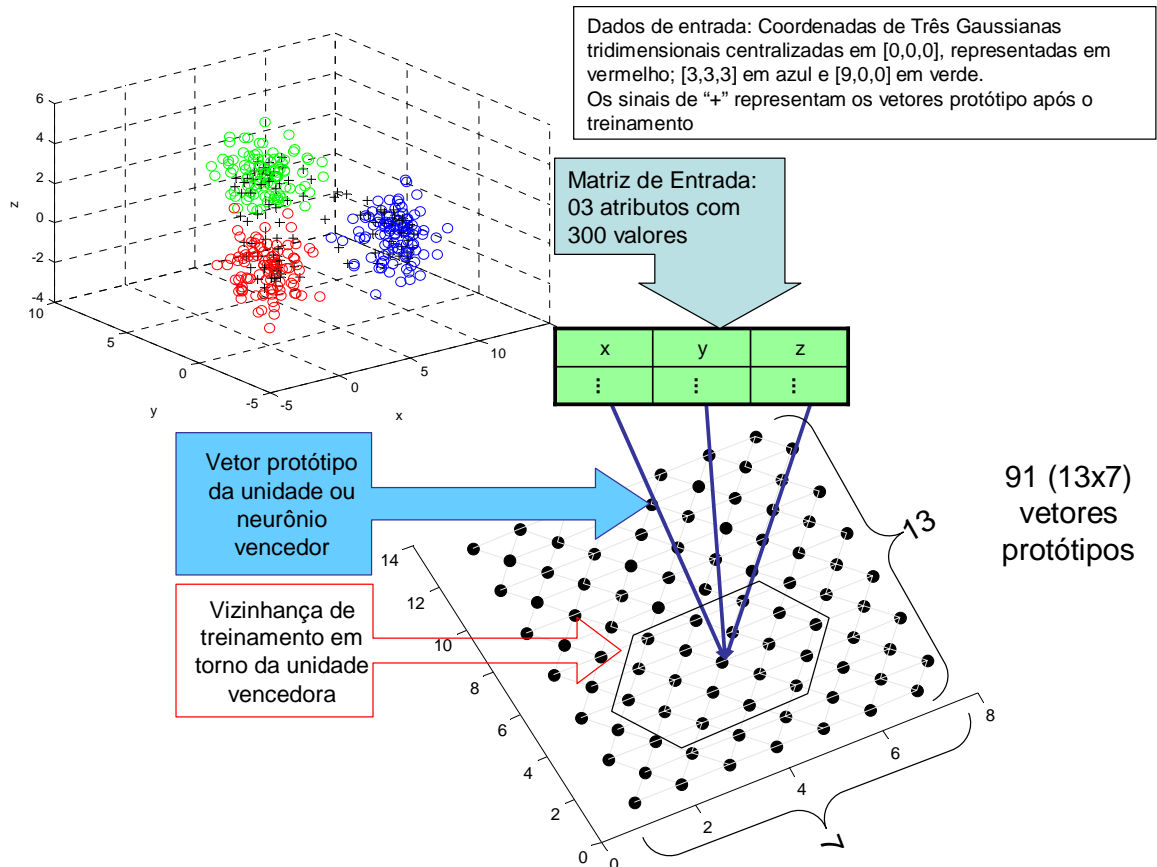


Figura 23: Exemplo de aplicação do SOM utilizando mapa com 91 (13x7) vetores protótipos, tendo como atributos de entrada as coordenadas de três gaussianas ligeiramente defasadas do espaço 3D.

Normalmente, o SOM é treinado de forma iterativa. Inicialmente, os vetores protótipos podem ser inicializados aleatoriamente ou ter os seus valores arbitrados usando, por exemplo, as projeções nos dois maiores autovetores dos dados de entrada. Então, a cada passo do treinamento, um vetor de entrada  $x$  é aleatoriamente escolhido do conjunto de dados de entrada. A distância entre  $x$  e todos os vetores protótipos é calculada. A unidade do mapa com menor distância ao vetor de entrada  $x$  (BMU - best matching unit) é chamada de  $b$ :

$$\|x - m_b\| = \min_i \{\|x - m_i\|\} \quad (20)$$

Em seguida, o vetor protótipo correspondente ao BMU e seus vizinhos são atualizados, sendo, portanto, movidos em direção ao vetor de entrada vencedor no espaço de entrada. A regra de atualização para a unidade  $i$  é dada por:

$$m_i(t+1) = m_i(t) + \alpha(t)h_{bi}(t)[x - m_i(t)] \quad (21)$$

onde  $t$  denota o tempo discreto,  $\alpha(t)$  é a taxa de aprendizado e  $h_{bi}(t)$  é o tamanho da vizinhança centrada na unidade vencedora que decresce ao longo do aprendizado e é dada por:

$$h_{bi}(t) = e^{-\frac{\|r_b - r_i\|^2}{2\sigma^2(t)}} \quad (22)$$

onde  $r_b$  e  $r_i$  são as posições dos neurônios  $b$  e  $i$  no reticulado do SOM.

Na figura 23 é apresentado um exemplo de análise de dados utilizando o SOM. Os dados de entrada são as coordenadas tridimensionais de três gaussianas ligeiramente defasadas espacialmente uma da outra. As coordenadas utilizadas como dados para a análise formam uma matriz com três colunas, representando cada uma um atributo de entrada. O número de linhas da matriz de entrada é dado pelo número de amostras disponíveis para análise, neste caso, 300.

O número de elementos do mapa foi definido através da relação empírica  $M = 5\sqrt{N}$ , enquanto as dimensões do mapa foram estabelecidas através da razão entre os dois maiores auto-vetores da matriz de covariância dos dados de entrada (Vesanto et al., 2000). Assim, foi formado para a análise um mapa bidimensional 13x7 com estrutura hexagonal, gerando, 91(=13x7) vetores protótipos com dimensão três. Nota-se que, neste caso em particular, o SOM está mapeando dados tridimensionais em bidimensionais.

A cada iteração do algoritmo o vetor protótipo vencedor será atualizado através da Eq 21, assim como seus vizinhos, utilizando a ponderação dada pela Eq 22.

Após o treinamento, os vetores protótipos representam uma forma de mapear os dados de entrada no SOM, bem como representam uma boa aproximação dos vetores de entrada, conforme se verifica no exemplo da figura 23, onde os vetores protótipos são representados pelo símbolo de “+”.

Neste exemplo, a visualização dos vetores protótipos é bastante didática e fácil de se entender. Entretanto, o número de atributos costuma ser bem maior do que três. Desta forma, como a visualização no espaço de entrada é impossível, uma das alternativas é utilizar as projeções dos vetores protótipos em outros espaços, como o formado pelos auto-vetores equivalentes aos dois maiores autovalores dos mesmos (Kohonen, 2001). Esta alternativa para a visualização do SOM, ilustrada na Fig 24, não será utilizada nesta tese.



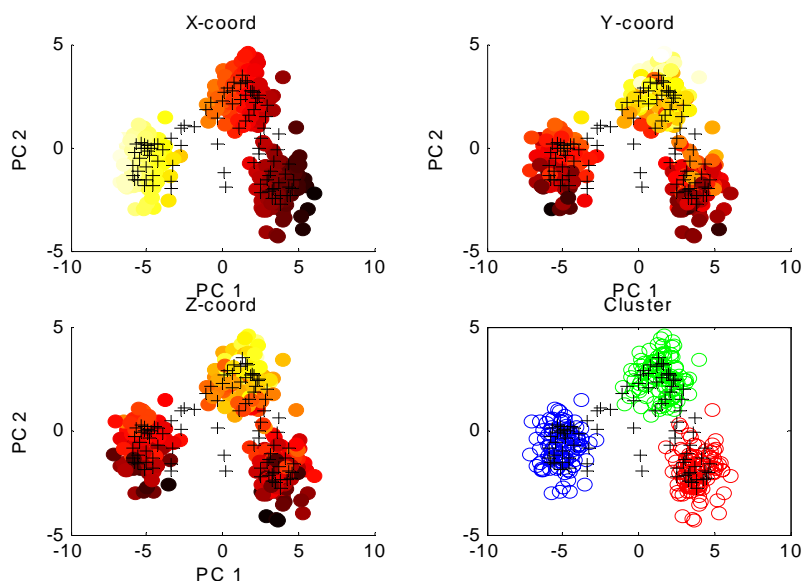


Figura 24: Projeção dos atributos de entrada e dos vetores protótipos após o treinamento nas duas componentes principais dos vetores protótipos formados.

Como o principal objetivo deste trabalho é a identificação de agrupamentos de dados, serão utilizados, para visualização do SOM, técnicas que enfatizem as correlações entre os pontos do mapa.

Visualizar as distâncias entre os vetores protótipos vizinhos é uma forma bastante interessante de se identificar similaridades entre os elementos do SOM. Especificamente, a matriz unificada de distância (Matriz-U) (Ultsch, 1993) é uma forma de representar tais distâncias.

Para a formação da matriz-U, após o treinamento, para cada elemento do SOM é calculada a distância entre os vetores protótipos vizinhos além da média entre eles. Por exemplo, para o elemento 18 do mapa, grifado na figura 25a, são calculadas as distâncias aos seus vizinhos, ie, aos elementos 10, 11, 17, 19, 24 e 25 e a média destas distâncias. Uma imagem utilizando o mapa gerado para o cálculo das distâncias é formada onde a intensidade de cada pixel da imagem é a respectiva distância estimada. Portanto, a matriz-U além de mostrar a distância média entre cada elemento, também ilustra o gradiente entre os mesmos. Na figura 25b, que ilustra a matriz-U para o exemplo da figura 23, observa-se que os pixels vermelhos ou amarelos, para a paleta RGB escolhida, representam elementos mais afastados, enquanto os pixels azuis representam os elementos mais próximos entre si. Desta forma, tem-se a impressão que três vales azuis densos estão separados por montanhas vermelhas e amarelas, ou seja, formam, neste caso em especial, três agrupamentos destacados dos outros. Logo a visualização através da matriz-U indica possíveis agrupamentos formados pelos

atributos representados pelo SOM, indicando, inclusive, o número de grupos existentes no dado.




Figura 25: (a) Ilustra como é formada a matriz-U; (b) Matriz-U para o exemplo da figura 5.

Outra forma interessante para visualização da similaridade entre vetores protótipos é plotar em cada elemento do mapa o seu respectivo vetor protótipo através de gráfico de barras, maçã ou linha. Para o caso especial do exemplo da figura 23, consegue-se visualizar a semelhança entre os vetores vizinhos dentro de cada um dos três agrupamentos indicados anteriormente pela matriz-U, como ilustrado na figura 26.

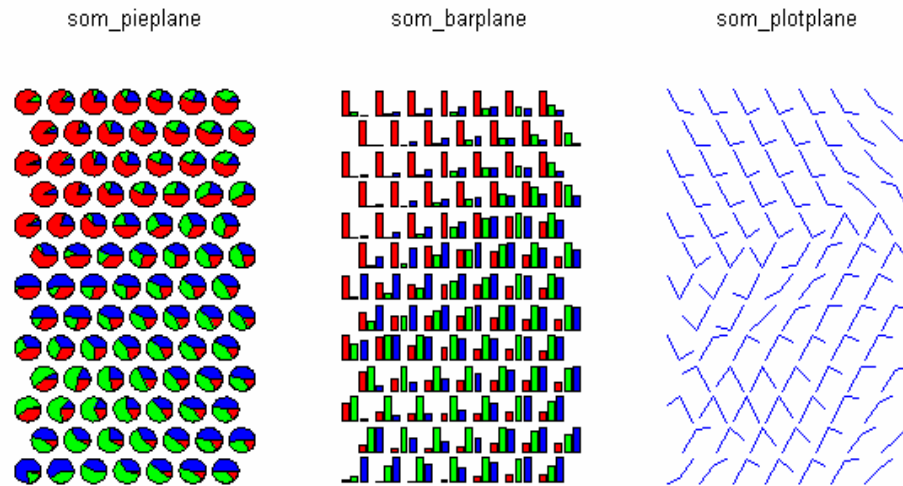


Figura 26: Representação dos vetores protótipos no mapa SOM.

### 3.3. Agrupamento do SOM

Em processos de mineração de dados, independente da área do conhecimento, o volume de dados costuma ser muito grande. Entretanto, as informações a respeito destes dados são, geralmente, precárias. Analogamente, em reconhecimento de padrões sísmicos, algumas informações não são conhecidas previamente. Por exemplo, a estimativa do número de fácies sísmica existente nos dados, em análises não-supervisionadas, é realizada de forma empírica.

Arbitrando-se o número de vetores protótipos do SOM muito maior que o número de grupos esperados nos dados, a partir da visualização do SOM, pode-se estimar a quantidade de agrupamentos existentes nos dados. Portanto, a visualização da formação de agrupamentos de dados com características em comum através do SOM é uma ferramenta bastante poderosa para análise de sinais. Entretanto, através da visualização, somente informações qualitativas podem ser obtidas.

Para se obter uma descrição quantitativa das propriedades dos dados, os grupos formados devem ser selecionados no SOM. Logo, baseado na visualização, os grupos poderiam ser escolhidos manualmente. Entretanto, como tal procedimento seria tedioso e geraria incertezas, propõe-se o agrupamento semi-automático dos dados através do agrupamento do SOM utilizando métodos tradicionais como o K-means.

A abordagem utilizada (Vesanto e Alhoniemi, 2000) neste trabalho consiste em se agrupar os vetores protótipos em lugar dos dados originais. Desta forma, grandes conjunto de dados, representado pelos vetores protótipos do SOM podem ser indiretamente agrupados. A figura 27 ilustra uma abstração do processo. O método proposto, além de dar um melhor entendimento sobre a formação dos grupos, tem como vantagem a redução drástica do tempo computacional (Vesanto, 2002). Outro benefício desta metodologia é a redução de ruído, visto que os vetores protótipos representam médias locais dos dados.

Cabe ressaltar que o objetivo deste trabalho não é a obtenção de uma forma ótima para clusterização de dados, mas sim de identificar e separar diferentes características em grandes conjuntos de dados, especificamente, dados sísmicos. Obviamente, esta abordagem somente é válida quando os grupos encontrados utilizando o SOM são similares àqueles do dado original. Outro fator a se cuidar é que sem um bom entendimento e uma preparação cuidadosa dos dados o resultado obtido pode ficar ininteligível, ou seja, para o caso específico de dados sísmicos, a escolha equivocada dos atributos sísmicos pode levar a conclusões errôneas.

O agrupamento do SOM pode ser realizado utilizando qualquer método tradicional, aglomerativo ou partitivo. Outras alternativas podem ser também utilizadas, entre elas, a de segmentar a matriz-U utilizando algoritmos de processamento de imagem (Costa, 1999). Especificamente, neste trabalho será utilizado um algoritmo de clusterização partitivo: o K-means.

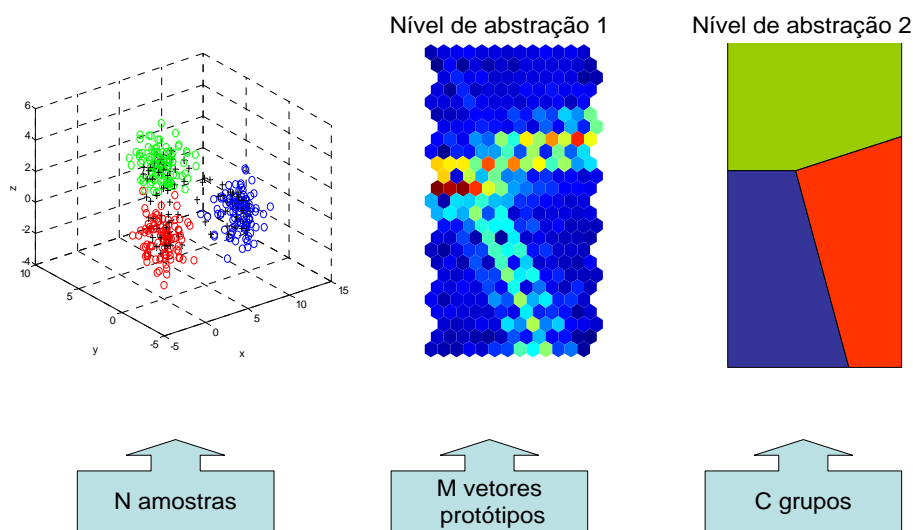


Figura 27: Abstração do processo de agrupamento do SOM.

### 3.3.1. Agrupamento partitivo: K-means

Uma possível definição para agrupamento ótimo seria aquele que minimiza a distância entre os elementos de cada grupo e maximiza a distância entre os diferentes clusters. Entretanto, como existem diversos modos para se efetuar tais medidas (Theodoridis e Koutroumbas, 1999), neste trabalho, optou-se pela norma euclidiana como padrão. Especificamente para a avaliação da distância entre os elementos de cada grupo, foi utilizada a distância média dos elementos do grupo ao seu centróide:

$$S_c = \frac{\sum_i \|x_i - c_k\|}{N_k} \quad (23)$$

onde  $c_k$  é o centróide do grupo  $k$  e  $N_k$  é o número de elementos do grupo.

Para avaliação da distância entre os grupos foi utilizada a distância entre os centróides:  $d_{ce} = \|c_k - c_l\|$ ; onde  $k \neq l$ .

Os algoritmos de agrupamento partitivos dividem o conjunto de dados em um número pré-definido de clusters tentando minimizar alguma função de erro, que no caso do k-means, é a distância média dos elementos de cada grupo ao seu centróide. O algoritmo consiste nos seguintes passos (Pandya e Macy, 1995):

1. Arbitrar o número de grupos;
2. Inicializar os centróides de cada grupo;
3. Distribuir as amostras entre os grupos utilizando como critério a proximidade entre cada amostra ao centróide dos grupos, ou seja, uma amostra pertence a um determinado grupo se a distância ao centróide do mesmo for menor que as distâncias aos centróides dos outros grupos;
4. Calcular os novos centróides de cada cluster, utilizando a média dos elementos de cada grupo;
5. Checar a convergência do processo, verificando se os centróides não se modificaram dentro de uma tolerância estipulada. Caso o processo não tenha convergido, deve-se voltar ao passo 3.

Analisando cuidadosamente o algoritmo acima, verifica-se que alguns fatores influenciam bastante no desempenho do mesmo, tais como o número de grupos arbitrados, a escolha inicial dos centróides de cada grupo, as propriedades geométricas dos dados e a possível existência de amostras muito

distante de todos os grupos, os “outliers”. Entretanto, como o objetivo é a aplicação do algoritmo K-means para a clusterização dos vetores protótipos do SOM, estes problemas podem ser minimizados.

Através da visualização do SOM pode-se arbitrar e verificar a escolha do número de grupos existente no dado. Entretanto, com o objetivo de auxiliar e automatizar o processo de classificação, optou-se por utilizar o índice de Davies-Bouldin (Davies e Bouldin, 1979) como forma de avaliar o particionamento do K-means. De acordo com índice de validação de Davies-Bouldin, o melhor agrupamento minimiza a eq.(24):

$$\frac{1}{C} \sum_{k=1}^C \max_{l \neq k} \left\{ \frac{S_c(Q_k) + S_c(Q_l)}{d_{ce}(Q_k, Q_l)} \right\} \quad (24)$$

onde  $C$  é o número de grupos,  $S_c$  é a distância entre as amostras dos grupos  $k$  e  $l$  e  $d_{ce}$  a distância entre os centróides dos respectivos grupos. Portanto, valores do índice de Davies e Bouldin menores que um representam agrupamentos separados, enquanto valores maiores que um representam grupos possivelmente cruzados.

Como os vetores protótipos do SOM são médias locais dos dados, o agrupamento dos mesmos será menos sensível a dados espúrios ou “outliers”.

### 3.4. Agrupamento do SOM aplicado à análise de fácies sísmicas

Baseado na clusterização do SOM, segue abaixo a proposta para análise não-supervisionada de padrões sísmicos:

- a) Segmentação espacial e temporal com orientação geológica;
- b) Seleção dos atributos sísmicos que serão utilizados como dados de entrada da análise;
- c) Formação e treinamento do SOM com número de vetores protótipos muito maior que o número esperado de fácies sísmicas;
- d) Utilizando a visualização da U-matrix do SOM, em comparação com o índice de Davies-Bouldin para diferentes números de agrupamentos, é estimado o número de fácies sísmicas;
- e) Clusterização e rotulação dos vetores protótipos do SOM utilizando o algoritmo partitivo K-means;
- f) Após os elementos do SOM serem rotulados com o número de fácies sísmicas estimado, os atributos sísmicos para cada ponto do reticulado de entrada são comparados com os vetores protótipos do SOM e então

classificados de acordo com as fácies do agrupamento para o qual pertence o vetor protótipo mais próximo.

g) Construção e Interpretação dos mapas de fácies sísmicas.

Uma grande contribuição desta metodologia está no auxílio na escolha do número de fácies sísmicas, normalmente, arbitrada de forma empírica.

### 3.4.1.Exemplo a: Análise de fácies sísmicas de um dado sintético.

Para verificar a eficácia do procedimento proposto um dado sísmico 3D sintético convolucional, composto por apenas duas linhas sísmicas foi gerado a partir do modelo da figura 28 ilustrada abaixo.

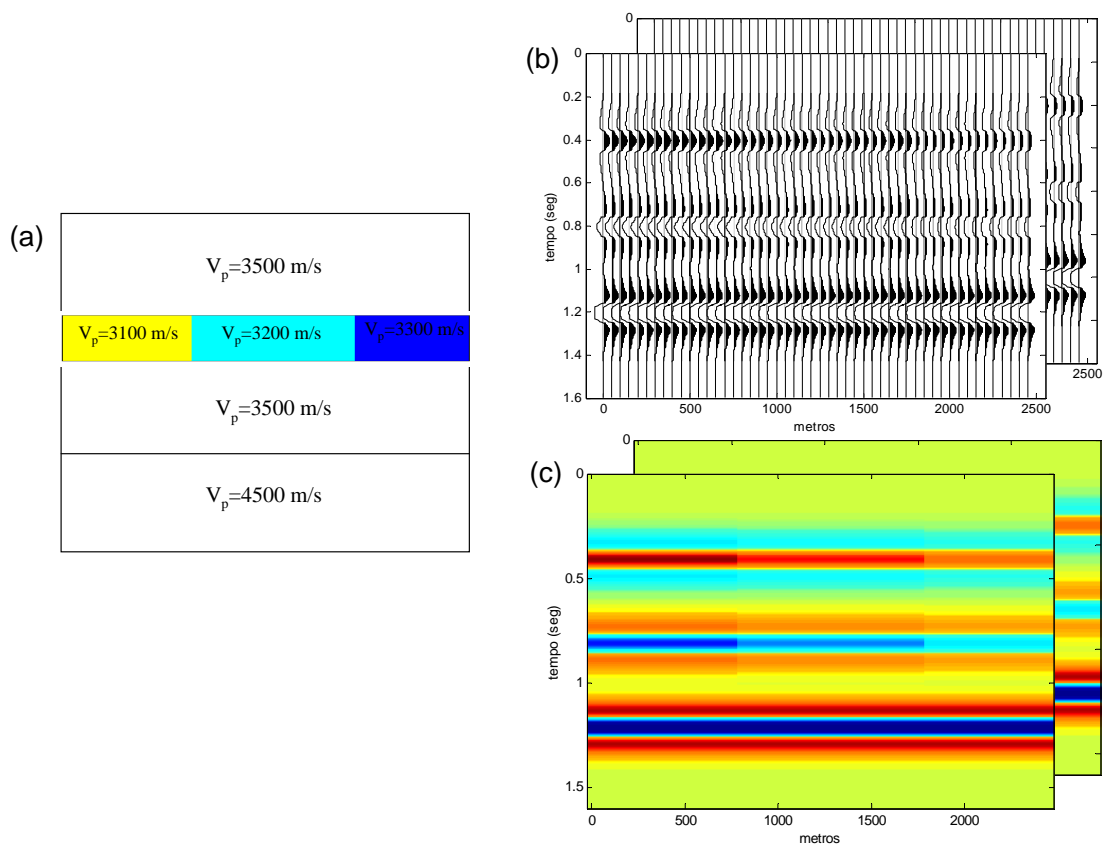


Figura 28: (a) Modelo esquemático com as velocidades de propagação de cada camada; (b) Sinal sísmico sintetizado a partir do modelo de velocidades; (c) O mesmo sinal sísmico representado como uma imagem.

Pode-se verificar que, na região onde ficaria localizado o suposto reservatório de petróleo, o referido modelo possui três diferentes fácies sísmicas, caracterizadas pelas velocidades de propagação de 3100 m/s, 3200 m/s e 3300 m/s (Santos, 1997).

Para esta análise foram utilizados como atributos sísmicos as amplitudes em torno do reservatório em questão (Poupon et al, 2003), (Saggaf et al, 2002), i.e., a região marcada em preto na figura 29a. A utilização das amplitudes instantâneas como atributos de entrada equivale a classificação das formas de onda na região de interesse. Tal procedimento utilizando outros algoritmos de classificação de fácies é diretamente aplicado por alguns softwares comerciais (Stratimagic, 2001). A análise com o algoritmo proposto, encontra-se na figura 29. Verifica-se para este caso em especial, que os três grupos ou fácies são facilmente identificados pela matriz-U e o resultado da classificação foi excelente. Entretanto, o índice mínimo de Davies-Bouldin 5 não correspondeu ao número de fácies existente. Portanto, a escolha do número de fácies deve sempre que possível ser feita de forma semi-automática, ou seja, deve-se confirmar a estimativa do número de fácies após a visualização da matriz-U.

A mesma análise foi realizada acrescentando-se ruído gaussiano ao modelo sísmico sintético. O resultado ilustrado na figura 30 confirma novamente o bom resultado obtido utilizando-se a metodologia proposta e a importância da visualização da matriz-U para a estimativa do número de fácies sísmicas.

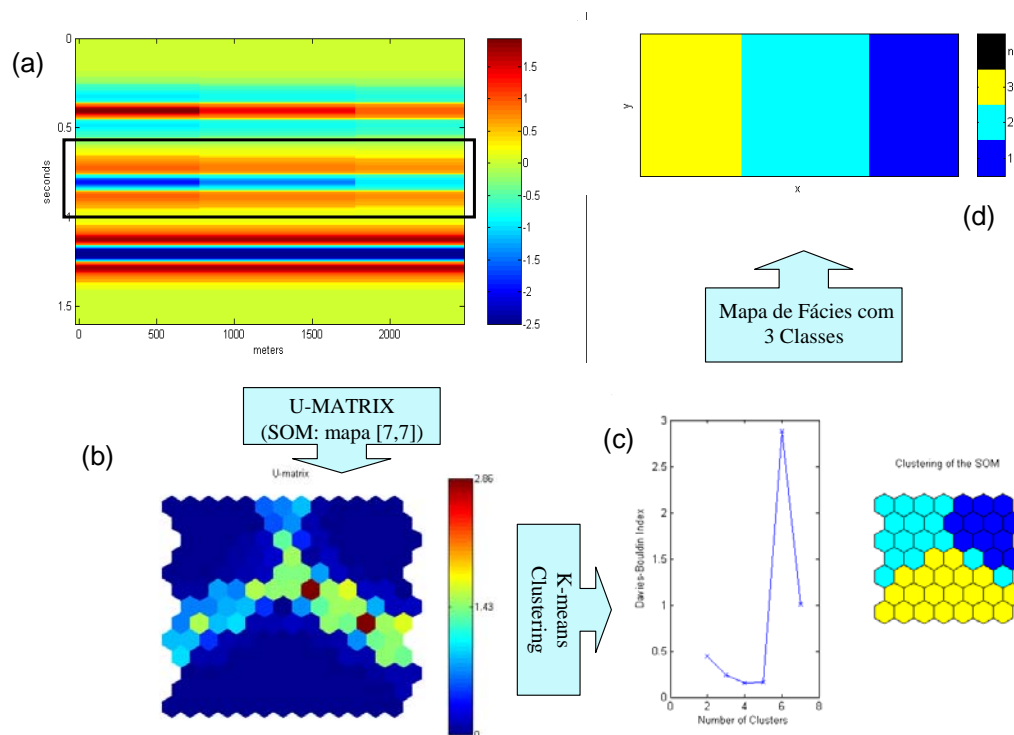


Figura 29: (a) Segmentação temporal do sinal sísmico; (b) Matriz-U; (c) Análise dos possíveis grupos formados pelo SOM via índice de Davies-Bouldin; (d) Mapa de fácies sísmicas gerado.



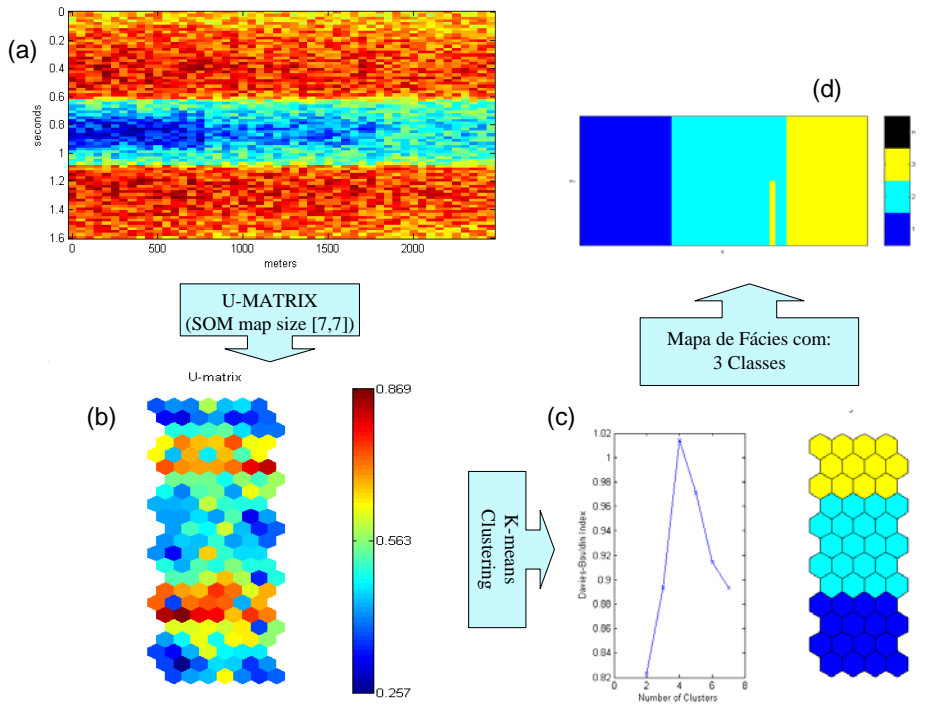


Figura 30: (a) Segmentação temporal do sinal sísmico; (b) Matriz-U; (c) Análise dos possíveis grupos formados pelo SOM via índice de Davies-Bouldin; (d) Mapa de fácies sísmicas gerado.

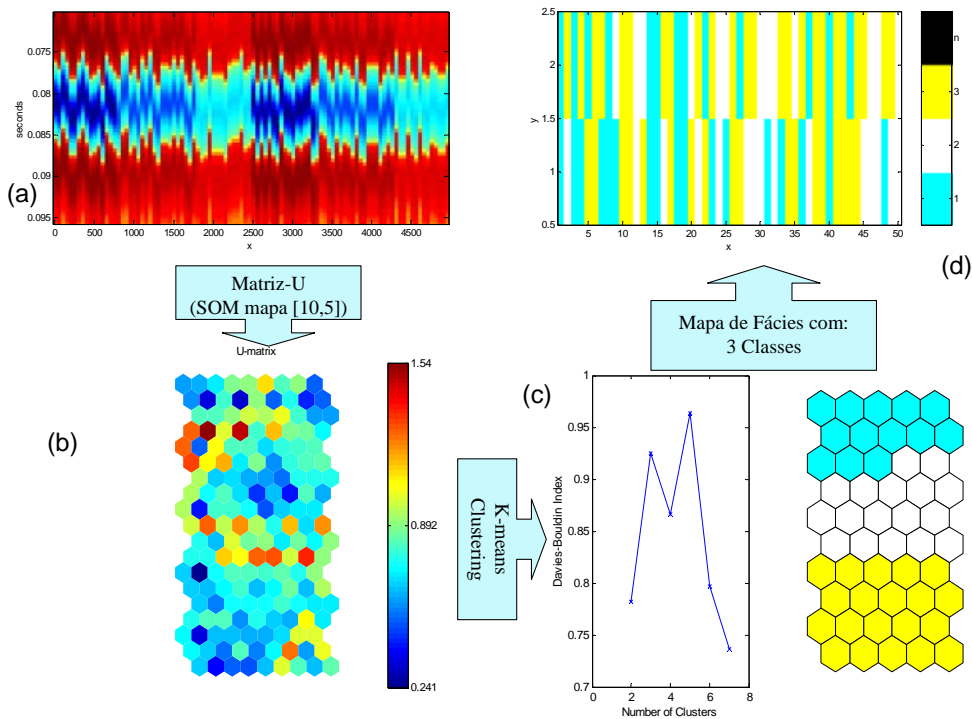


Figura 31: (a) Segmentação temporal do sinal sísmico; (b) Matriz-U; (c) Análise dos possíveis grupos formados pelo SOM via índice de Davies-Bouldin; (d) Mapa de fácies sísmicas gerado.

Entretanto, ao simular uma interpretação ruidosa dos horizontes que delimitam a região de interesse, a análise de fácies sísmicas utilizando a metodologia proposta, obteve um resultado muito ruim, conforme ilustrado na figura 31. Tal fato se deve ao atributo sísmico utilizado, amplitude instantânea, ser sensível a deslocamentos no tempo (Rankel&Mitchel, 2003). Logo, a escolha dos atributos sísmicos para a classificação de padrões sísmicos é fundamental para a obtenção de resultados coerentes.

### **3.4.2. Análise de fácies sísmicas de um dado real.**

A metodologia proposta para análise de fácies sísmicas foi aplicada em um dado sísmico 3D real da Bacia de Campos, disponibilizado pela Petrobrás e já ilustrado nas figuras 1 e 2. Nove amostras da unidade estratigráfica superior do reservatório (Johann, 1999) foram utilizadas como atributo de entrada. Como a variação de espessura do reservatório é bastante grande, para evitar a utilização de amostras fora da área de interesse, foram geradas nove amostras interpoladas dentro da referida unidade estratigráfica, conforme ilustrado na figura 32.

A análise de fácies sísmicas está ilustrada na figura 33. Verifica-se que não se pode confirmar a existência de grupos bem definidos através da matriz-U, mas sim da existência de um único grupo com possíveis pequenas divisões, o que significa que não existe uma divisão clara entre as formas de onda preponderantes no dado real analisado. Estimando-se o número de fácies através do índice mínimo de Davies-Bouldin, observa-se que o resultado do agrupamento obtido com seis fácies sísmicas é aceitável, mas não totalmente justificável. Sabe-se da análise petrofísica (Johann, 1999) do dado em questão, que o número real de fácies é quatro. O respectivo mapa com este número de fácies também é mostrado na figura 33.

Portanto, nem sempre através do agrupamento do SOM pode-se identificar de forma clara o número de fácies sísmicas presentes no dado. Neste caso, em especial, a escolha do atributo amplitude instantânea não se mostrou como a mais adequada para a identificação das fácies sísmicas. Provavelmente, por causa da grande variação das formas de onda na região de interesse, visto se tratar de um dado originário de um sistema turbidítico bastante complexo. Logo, a preparação e seleção dos atributos sísmicos devem ser realizadas de forma bastante criteriosa, refletindo corretamente a natureza da característica que se deseja analisar e identificar.




Figura 32: Interpolação das amplitudes instantâneas na região de interesse.

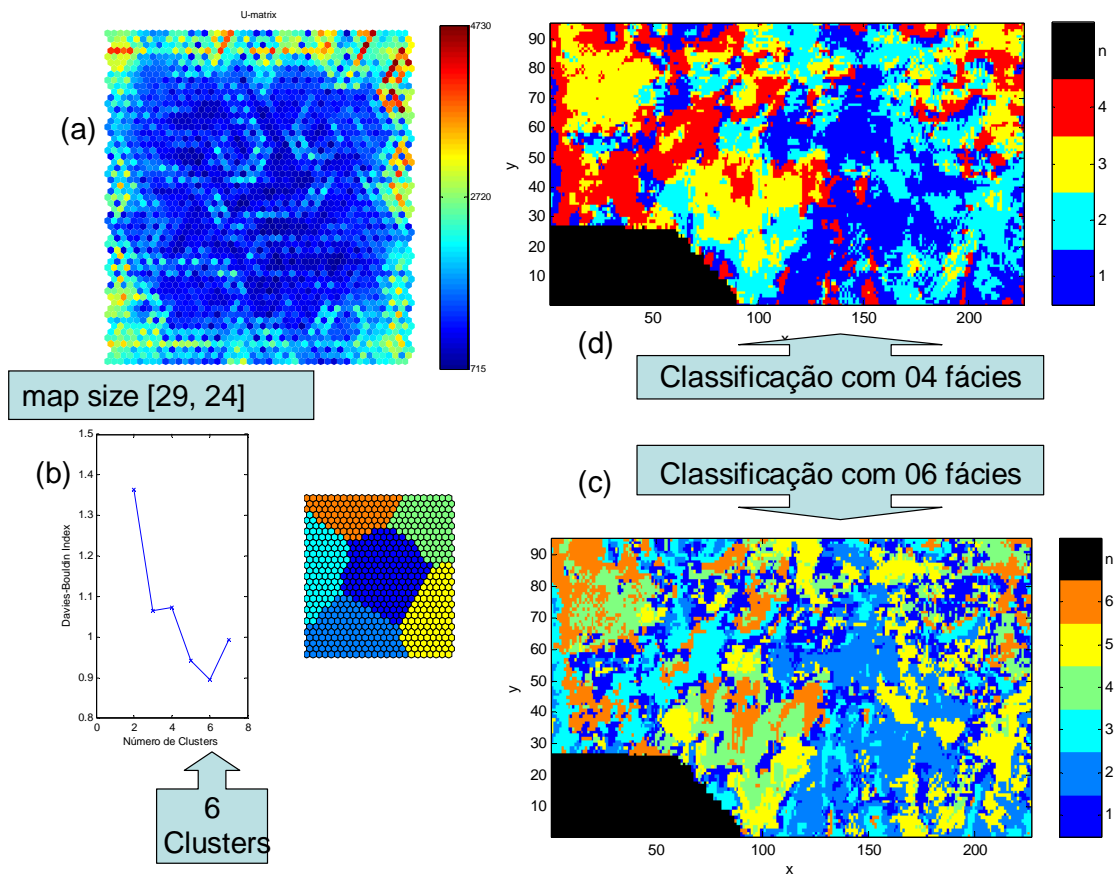


Figura 33: Análise de fácies utilizando dados reais.