

**NATHÁLIA SEILER SPADA**

**Classificação litológica e identificação de zonas permoporosas em perfis de  
poços com base em redes neurais artificiais não supervisionadas**

Santos

2018

**NATHÁLIA SEILER SPADA**

**Classificação litológica e identificação de zonas permoporosas em perfis de  
poços com base em redes neurais artificiais não supervisionadas**

Trabalho de Formatura em Engenharia de  
Petróleo do curso de graduação do  
departamento de Engenharia de Minas e  
de Petróleo da Escola Politécnica da  
Universidade de São Paulo

Orientador: Prof. Dr. Cleyton de Carvalho  
Carneiro.

Co-orientador: Lucas Blanes de Oliveira

Santos

2018

NATHÁLIA SEILER SPADA

**NATHALIA SELER SPADA** *Analista de Sistemas, com especialização em Desenvolvimento de Sistemas. Bacharelado em Ciências da Computação. Atualmente é Analista de Sistemas na Seler Spada Sistech. Atua no desenvolvimento de sistemas para a área de Saúde, com destaque para a área de Gestão de Informações Clínicas (GIC).*

## Classificação litológica e identificação de zonas permoporosas em perfis de poços com base em redes neurais artificiais não supervisionadas

Trabalho de Formatura em Engenharia de  
Petróleo do curso de graduação do  
departamento de Engenharia de Minas e  
de Petróleo da Escola Politécnica da  
Universidade de São Paulo

## Área de Concentração: Engenharia de reservatórios, perfilagem de poços.

Orientador: Prof. Dr. Cleyton de Carvalho Carneiro.

Co-orientador: Lucas Blanes de Oliveira

Santos

2018

## AGRADECIMENTOS

Agradeço primeiramente a meus pais e minha irmã, que sempre torceram por meu sucesso e me incentivaram a persistir sempre que os problemas pareciam difíceis demais.

A todos os professores, a direção e administração da Escola Politécnica, especialmente do campus de Santos, que foram fundamentais no meu desenvolvimento acadêmico e sempre estiveram dispostos a ajudar em momentos que recorri a eles.

A meu orientador Prof. Dr. Cleyton de Carvalho Carneiro, não somente pelas orientações e confiança em meu trabalho mas também pelo acompanhamento durante os últimos três anos.

Não posso deixar de agradecer a todos os meus amigos, tanto os que a faculdade me trouxe, quanto aos que têm estado presentes desde sempre. Obrigada pelos conselhos, palavras de apoio, puxões de orelha e risadas. Em especial às meninas que moraram comigo, obrigada por termos criado tantas memórias inesquecíveis.

## RESUMO

A técnica de perfilagem de poços de petróleo consiste em um relevante mecanismo para a compreensão estratigráfica de bacias sedimentares bem como para o detalhamento de reservatórios de hidrocarbonetos. Tradicionalmente, as interpretações destes perfis são elaboradas por interpretação visual, tendo como base as diferentes respostas de registros físico-químicos apresentados nos perfis geofísicos dos poços, ou através de redes neurais artificiais supervisionadas. Estes formatos de interpretação apresentam limitações, especialmente em áreas pouco exploradas, onde o conhecimento prévio é reduzido. O presente trabalho utiliza a técnica *Self-Organizing Maps* (SOM), uma rede neural artificial não supervisionada, no intuito de identificar e individualizar padrões de similaridade em perfis geofísicos de múltiplos poços, para que estes possam ser traduzidos em classes litológicas. Foram analisados, em conjunto, dados de quatro diferentes poços da Bacia de Santos, no Pré-sal brasileiro. Através da metodologia empregada verificou-se uma boa correlação entre os resultados obtidos pelo SOM e pela técnica usual de interpretação visual, sendo identificado cinco diferentes grupos litológicos (carbonatos, lamitos e argilas magnesianas). Em uma segunda etapa, foram identificados os perfis que melhor se adequam a identificação de zonas com diferentes permoporosidades. Como resultado, obteve-se clara separação entre zona de óleo e zona de água, além da determinação de trechos mais permoporosos em ambas as zonas.

**Palavras-Chave:** Perfilagem de poços. Mapas auto-organizáveis. Redes neurais artificiais.

## ABSTRACT

The technique of well logging consists of a relevant mechanism for the stratigraphic understanding of sedimentary basins as well as for the detailing of hydrocarbon reservoirs. Traditionally, the interpretations of these logs are elaborated by visual interpretation, based on the different responses of physical-chemical records presented in the geophysical well logs, or through supervised artificial neural networks. These interpretation present limitations, especially in poorly explored areas where prior knowledge is reduced. This work uses the Self-Organizing Maps (SOM) technique, an unsupervised artificial neural network, in order to identify and individualize patterns of similarity in geophysical logs of multiple wells, so that they can be translated into lithologic classes. Data from four different wells of the Santos Basin in the Brazilian Pre-salt were analysed. A good correlation was found between the results obtained by SOM and the usual visual interpretation technique. Five different lithological groups were identified. In a second stage, the profiles that best fit the identification of zones with different permoporosities were identified. As a result, a clear separation between oil zone and water zone was obtained, in addition to the determination of more permoporous stretches in both zones.

**Keywords:** Well logging. Self-Organizing Maps. Artificial neural network.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>8</b>
<b>2</b>	<b>OBJETIVOS .....</b>	<b>10</b>
2.1	OBJETIVOS ESPECÍFICOS .....	10
<b>4</b>	<b>REVISÃO DA LITERATURA .....</b>	<b>11</b>
4.1	MÉTODOS DE EXPLORAÇÃO DE UM CAMPO DE PETRÓLEO .....	11
4.2	PERFIS GEOFÍSICOS DE POÇOS .....	12
4.2.1	<i>Perfil de Resistividade .....</i>	12
4.2.2	<i>Perfil Sônico (DT) .....</i>	13
4.2.3	<i>Perfil de Densidade (RHOB) .....</i>	14
4.2.4	<i>Perfil Neutrônico (NPHI) .....</i>	14
4.2.5	<i>Ressonância Magnética Nuclear (NMR) .....</i>	15
4.2.6	<i>Raios Gama Natural (GR) .....</i>	16
4.2.7	<i>Espectroscopia de raios gama natural .....</i>	16
4.2.8	<i>Espectroscopia de raios gama induzido .....</i>	17
4.3	REDES NEURAIS ARTIFICIAIS .....	18
4.4	SELF-ORGANIZING MAPS .....	20
<b>5</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>23</b>
5.1	MATERIAIS .....	23
5.2	MÉTODOS .....	25
5.2.1	<i>Definição dos parâmetros de entrada .....</i>	25
5.2.2	<i>Descrição do procedimento .....</i>	26
5.2.3	<i>Validação da metodologia de classificação litológica .....</i>	27
<b>6</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>29</b>
6.1	PREPARAÇÃO DOS DADOS PARA A SEPARAÇÃO LITOLÓGICA .....	29
6.2	DEFINIÇÃO DE DIFERENTES LITOLOGIAS .....	30
6.3	VALIDAÇÃO DOS RESULTADOS LITOLÓGICOS .....	34
6.3.1	<i>Comparação com interpretação de geólogos .....</i>	34
6.3.2	<i>Comparação com amostras laterais .....</i>	39
6.4	SEPARAÇÃO DE FLUIDOS E IDENTIFICAÇÃO DE ZONAS PERMOPOROSAS .....	40
<b>7</b>	<b>CONCLUSÕES .....</b>	<b>42</b>
	<b>REFERÊNCIAS .....</b>	<b>43</b>

## 1 INTRODUÇÃO

A descoberta de grandes reservatórios de óleo leve no Pré-Sal das Bacias de Campos e Santos atraíram a atenção da indústria do petróleo no país. A descoberta destes novos campos foi classificada como uma das maiores e mais significativas descobertas de petróleo das últimas décadas e, atualmente, a produção do Pré-sal corresponde a cerca de 54% do total produzido no Brasil (Boletim da Produção de Petróleo e Gás Natural, 2018; CHAUHAN; MOURIK; FLORENCIO, 2014).

Estes promissores reservatórios selados pela espessa sedimentação evaporítica são compostos, predominantemente, por variedades de carbonatos. Tal família de rochas apresenta uma natureza complexa e heterogênea de porosidade, permeabilidade e continuidade vertical das camadas (BURCHETTE, 2012), fatores que aumentam a complexidade da caracterização petrofísica e, consequentemente, da sua produção implicando em elevado investimento e alto custo de produção (MELLO, 2015).

Para o melhor entendimento geológico do campo e análise das incertezas associadas à exploração e produção de óleo e gás faz-se uso da caracterização de reservatórios. A caracterização, portanto, combina conhecimentos de diversos áreas, tais como: (i) análise geológica, envolvendo modelos deposicionais, diagenéticos e estruturais; (ii) engenharia de petróleo, compreendendo a geração de modelos de fluxo; (iii) métodos estatísticos, sejam estes clássicos ou geoestatísticos; (iv) métodos de interpretação de dados sísmicos, envolvendo modelos elásticos dentre outros; (v) métodos numéricos; e (vi) métodos de computação gráfica (BALDISSERA; REMACRE; TIBANA, 1992). Todas essas áreas irão auxiliar na construção de modelos integrados, onde são reunidas as informações e dados disponíveis sobre o reservatório para se prever, monitorar e otimizar a performance do mesmo durante todo o seu ciclo de vida.

Dentre os mais importantes métodos de exploração e caracterização de reservatórios encontram-se os perfis geofísicos de poços ou “well logs”, onde parâmetros relacionados à porosidade, litologia, presença de hidrocarbonetos e outras propriedades das rochas podem ser obtidos (SERRA, 1984). De posse de tais interpretações torna-se possível a elaboração de modelos estratigráficos das bacias sedimentares bem como o detalhamento de reservatórios de hidrocarbonetos.

Tradicionalmente, as interpretações destes perfis são elaboradas por interpretação visual, tendo como base as diferentes respostas de registros físico-químicos. Além desse formato, tais interpretações por vezes se baseiam em redes neurais artificiais, sobretudo aquelas supervisionadas, onde há a necessidade de inserção de parâmetros de treinamento definidos por um especialista. Estes formatos de interpretação apresentam limitações, especialmente em áreas pouco exploradas, onde o conhecimento *a priori* é reduzido.

Com o propósito de alcançar um melhor entendimento das diversidades presentes nos campos carbonáticos propõe-se o desenvolvimento de novas estratégias computacionais que auxiliem a interpretação de dados de caracterização de reservatórios e a tomadas de decisões, diminuindo riscos e incertezas associados.

Existem diversos métodos de modelagem espacial de dados que possibilitam o aperfeiçoamento do processo de interpretação a partir da atribuição de parâmetros sistemáticos e semiautomáticos. São exemplos de técnicas de modelagem espacial de dados as guiadas pelo conhecimento (*knowledge-driven*), ou aquelas guiadas pelos dados (*data-driven*). O método Self-Organizing Maps – SOM (KOHONEN, 1997) ou Mapas Auto Organizáveis é uma abordagem *data-driven* e foi selecionado para este trabalho visto que possibilita a melhor visualização das relações topológicas e topográficas dos dados e suas propriedades.

A técnica SOM foi aplicada visando a tradução dos perfis de diversos poços em classes litológicas, observando constituição, geometria e abrangência das classes geradas. Em uma segunda etapa, perfis serão selecionados e utilizados como base para identificação automática de zonas com maior permotorosidade.

## 2 OBJETIVOS

O estudo ora proposto tem como objetivo principal identificar e individualizar padrões de similaridade em perfis geofísicos de múltiplos poços a partir da técnica “*Self-Organizing Maps*” tendo em vista a interpretação litológica e identificação de zonas com maior permoporosidade.

### 2.1 OBJETIVOS ESPECÍFICOS

- Investigar a sistemática de classificação em poços do Pré-sal, com variações faciológicas dos carbonatos;
- Determinar perfis que melhor se relacionam com regiões permoporosas.

## 4 REVISÃO DA LITERATURA

### 4.1 MÉTODOS DE EXPLORAÇÃO DE UM CAMPO DE PETRÓLEO

Durante toda a etapa de prospecção até a consolidação da produção de um poço de petróleo é necessária a determinação das propriedades geométricas e estruturais que o condicionam. Existem diversos estudos que visam identificar as áreas favoráveis à acumulação de hidrocarbonetos, e estes se dividem em estudos geológicos e geofísicos. Os estudos geológicos têm como objetivo reconstituir as condições de formação e acumulação de hidrocarbonetos numa determinada região através de métodos de análise da superfície como aerofotogrametria, fotogeologia e características geológicas das rochas obtidas em poços exploratórios. Já os estudos geofísicos têm como principal objetivo obter informações sobre a presença, posição e natureza das estruturas geológicas em subsuperfície, utilizando medidas das suas propriedades físicas, através de gravimetria, magnetometria, sísmica e perfilagem (THOMAS, 2001).

O método gravimétrico baseia-se nas medições e interpretação das variações do campo gravitacional terrestre resultantes das diferenças de densidade entre as rochas localizadas em superfície e subsuperfície (ERNESTO; USSAMI, 2002). Por meio da gravimetria é possível a identificação de rochas com densidades anômalas, tais como as ígneas ou sedimentares com estruturas salinas, sendo que as zonas com menor densidade são mais propícias à existência de hidrocarbonetos. A magnetometria, por sua vez, se baseia na medida de anomalias do campo magnético da Terra para fornecer informações da geologia de superfície e subsuperfície. Assim, é possível identificar uma potencial acumulação de hidrocarbonetos uma vez que as rochas sedimentares, onde estes comumente se acumulam, têm uma suscetibilidade magnética muito baixa (ERNESTO; USSAMI, 2002; THOMAS, 2001). Já os estudos sísmicos se encontram entre os mais relevantes na prospecção inicial de petróleo e baseiam-se na emissão, transmissão e reflexão de ondas acústicas entre dois ou mais meios físicos de propriedades elásticas distintas (NETO, 2001). Esta técnica envolve a geração de ondas sísmicas artificiais que se propagam ao longo das rochas e dos reservatórios. Em seguida, as ondas são refletidas para receptores que registram a informação recebida, fornecendo dados sobre a disposição estrutural das camadas sedimentares, suas

espessuras, mergulho, presença de falhas e outros fatores que podem indicar a existência de reservas de hidrocarbonetos.

Após as análises dos resultados dos métodos descritos acima, tem-se a alocação de poços exploratórios, e posteriormente de produção e injeção. A partir deste momento a perfilagem geofísica passa a desempenhar papel fundamental no estudo de um campo (ELLIS; SINGER, 2008).

#### **4.2 PERFIS GEOFÍSICOS DE POÇOS**

Thomas (2001) define perfilagem como o registro, em função da profundidade, de uma ou mais características das formações rochosas atravessadas pelo poço. Por meio desta técnica busca-se identificar propriedades das rochas e fluidos presentes em subsuperfície através de informações elétricas, acústicas, termais e radioativas coletadas por sensores descidos no interior do poço.

Devido à ampla variedade de formações geológicas, interferência causada pela presença de fluidos (água ou hidrocarbonetos) e respostas ambíguas das ferramentas de perfilagem é necessário o uso de diferentes princípios físicos de medição. Tais respostas geradas, se analisadas de maneira conjunta, geram as melhores previsões dos tipos de rochas presentes, espessura das camadas, porosidade, permeabilidade, entre outras características relevantes para a produção de petróleo.

As técnicas de perfilagem existentes são guiadas por três grupos de princípios mais convencionais: (i) elétricos; (ii) nucleares; e (iii) acústicos. Os principais perfis utilizados e suas técnicas de leitura são apresentados a seguir.

##### **4.2.1 Perfil de Resistividade**

A resistividade de um material é definida como o inverso de sua condutividade, que consiste na capacidade de um material em transmitir corrente elétrica.

A condutividade de uma formação sedimentar dependerá principalmente da presença de sais dissolvidos na água da formação ou de uma combinação desta água e hidrocarbonetos no espaço poroso como uma fase contínua. A temperatura também é um fator relevante devido a variação da viscosidade dos líquidos ser fortemente relacionada a temperatura (ELLIS; SINGER, 2008).

É importante notar que a invasão do filtrado do fluido de perfuração irá causar mudanças na configuração dos fluidos da formação. Sendo assim, ferramentas de resistividade leem diversas profundidades de investigação para melhor entender o

perfil de invasão e poder indicar a presença de diferentes fluidos (água ou hidrocarboneto) (ARCHIE, 1941).

As ferramentas de resistividade podem utilizar também o princípio de indução eletromagnética, onde uma corrente elétrica transmitida por uma bobina (*transmitter*) gera um campo magnético ao seu redor que se propaga na formação. A formação, sob influência desse campo, gera um fluxo de corrente elétrica concêntrico que, por sua vez, gera um novo campo magnético. Esse novo campo irá gerar uma corrente em uma bobina receptora (*receiver*) que será convertida na resistividade da formação. A utilização deste princípio surgiu da necessidade da medida da resistividade em poços perfurados com fluido base óleo (DOLL, 1949).

#### 4.2.2 Perfil Sônico (DT)

O perfil sônico indica a diferença nos tempos de trânsito de uma onda mecânica através das rochas atravessadas pelo poço (THOMAS, 2001). Os princípios da exploração acústica de poços são baseados na teoria da propagação de ondas em um meio elástico: o movimento oscilante gerado por uma fonte sonora (*transdutor*) em um meio elástico (formação rochosa), chamado de onda acústica, se propaga através do poço e da formação. Quando a onda encontra a interface fluido/formação (parede do poço), esta é refratada. Ao atingir o ângulo de refração crítico de 90° com a interface, uma nova onda é emitida, agora da formação para o poço que viaja com a velocidade da onda na formação. O conjunto de ondas emitidas formará uma frente de onda que será lida pelos receptores da ferramenta (ELLIS; SINGER, 2008).

Ondas acústicas têm quatro propriedades mensuráveis: velocidade, amplitude, atenuação de amplitude e frequência. As ferramentas de registro acústico são projetadas para medir uma ou mais dessas propriedades, sendo o inverso da velocidade (vagarosidade) a mais comum.

Dentre os principais usos desta ferramenta, pode-se citar a calibração da sísmica (relação tempo-profundidade), o cálculo de porosidade, cálculo de propriedades mecânicas da rocha, identificação de fluidos, estimativa de pressão, cálculo de permeabilidade e identificação de fraturas (WILLIAMS, 1990).

É válido mencionar as diferentes formas de propagação de ondas no interior de um meio elástico. As ondas compressionais (P) têm direção de vibração das partículas paralela à direção de propagação da onda, é mais rápida e se propaga

tanto em fluidos quanto em sólidos. Já as ondas cisalhantes (S) têm direção de vibração das partículas perpendicular a direção de propagação da onda e se propaga apenas em sólidos. Este princípio pode ser aplicado na identificação de zonas de gás.

#### **4.2.3 Perfil de Densidade (RHOB)**

Nesta técnica de perfilagem utiliza-se uma fonte radioativa normalmente de Cs-137 que emite raios gama na formação. A interação desta radiação com a formação irá variar de acordo com as características dos átomos que a compõem gerando uma atenuação da energia dos raios gama que será lida nos receptores da ferramenta. As características da atenuação dos raios gama serão proporcionais a densidade eletrônica da formação, a qual tem relação com a densidade *bulk* e a composição química da formação (ELLIS; SINGER, 2008).

No caso de rochas porosas, como a medição realizada inclui a densidade do fluido alojado nos poros da rocha, além da determinação da densidade das camadas de rocha e das propriedades da matriz e fluido presentes, pode-se estimar a porosidade da formação e identificar possíveis zonas de gás (THOMAS, 2001)

Os dados medidos são muito sensíveis às condições externas; sendo assim, esta ferramenta deve correr junto a parede do poço diminuindo a interferência do ambiente do poço nas leituras. Visando corrigir anomalias geradas por efeito de parede de poço, como interferência do reboco ou arrombamento, é usado mais de um receptor de sinal de forma que a relação entre eles forneça um fator de correção que é aplicado a leitura do receptor mais distante, que sofre menos influência de efeito de parede de poço.

#### **4.2.4 Perfil Neutrônico (NPHI)**

As ferramentas neutrônicas são constituídas de uma fonte de nêutrons (normalmente AmBe) que emite nêutrons rápidos, os quais penetram nas camadas adjacentes ao poço. Estes nêutrons colidem com átomos de hidrogênio que diminuem sua velocidade e energia, até atingirem o nível termal do meio. Esta desaceleração será lida nos receptores da ferramenta e estará relacionada ao índice de hidrogênio da formação, do qual pode-se estimar a porosidade (ELLIS; SINGER, 2008; SERRA, 2008).

Assim como no perfil de densidade, esta ferramenta deve correr colada a parede do poço. Diversas correções podem também ser aplicadas para reduzir as

interferências externas a formação, mas estas podem carregar muitas incertezas (por exemplo, salinidade da formação). Dessa forma, é recomendado analisar os dados deste perfil de maneira conjunta ao de densidade para se obter informações quanto a matriz da formação, melhores estimativas de porosidade e identificar fluidos presentes.

#### **4.2.5 Ressonância Magnética Nuclear (NMR)**

Ressonância magnética nuclear é um fenômeno físico onde núcleos expostos a um campo magnético absorvem e reemitem radiação eletromagnética. Essa energia existe em uma frequência específica de ressonância, que depende da intensidade do campo magnético e das propriedades magnéticas dos isótopos dos átomos (ELLIS; SINGER, 2008).

A ferramenta de registro eletromagnético mede o momento magnético induzido de núcleos de hidrogênio (prótons) contidos no espaço poroso, ou seja, de fluidos em rochas reservatório. Ao contrário das medições de registro convencionais como sônico, densidade, nêutrons e resistividade, que respondem tanto à matriz da rocha como às propriedades do fluido e são fortemente dependentes da mineralogia, as medições de RMN respondem prioritariamente à presença de prótons de hidrogênio dos fluidos, visto que os prótons presentes nas hidroxilas têm rápido decaimento e não influenciam na leitura. O H presente nas lamelas das argilas (na forma de  $H_2O$ ) também é lido contudo, este pode ser identificado pelos baixos tempos de relaxação e excluído de eventuais avaliações (BRANCO, 2012).

Esta técnica fornece informações sobre as quantidades de fluidos presentes e suas propriedades, os tamanhos dos poros que contêm tais fluidos e consequentemente estimativas de fluido livre na formação, que pode ser proporcional a permeabilidade (ELLIS; SINGER, 2008). O uso desta técnica tem sido de alta relevância na exploração de carbonatos do Pré-sal.

Alguns problemas encontrados no uso desta técnica são: grande interferência das leituras por rugosidade e arrombamentos na parede do poço, profundidade de investigação rasa sendo, portanto, muito afetada pelo filtrado do fluido de perfuração (ELLIS; SINGER, 2008).

#### 4.2.6 Raios Gama Natural (GR)

O registro de raios gama natural é baseado na medição da radioatividade natural das rochas, ou seja, na energia liberada no decaimento espontâneo dos átomos de certos isótopos em outros isótopos. (SERRA, 1984).

Existe uma forte correlação entre o conteúdo de isótopos radioativos e a presença de alguns minerais, principalmente os siliciclásticos. Tendo isso em mente, ferramentas de registro foram desenvolvidas para ler os raios gama emitidos por esses elementos e interpretar a litologia a partir das informações coletadas. Os elementos utilizados nesta técnica são os isótopos radioativos de potássio (K), tório (Th) e urânio (U) (ELLIS; SINGER, 2008). O potássio é encontrado principalmente em feldspatos potássicos, micas, é ausente em minerais máficos e mais baixo em basaltos máficos. A presença de urânio é observada em minerais insolúveis, apresentando-se em meios redutores (carbonatos), em óxidos e silicatos minerais, e em minerais de zircão. Em folhelhos, este pode ser correlacionado com o conteúdo de matéria orgânica.

As variações no perfil GR estão, portanto, relacionadas à presença de matéria orgânica, feldspatos e argilominerais. Neste caso, é possível identificar as regiões da seção que apresentaram maiores acumulações de matéria orgânica e aquelas regiões onde o sinal foi atenuado por efeitos de lixiviação e oxidação.

Esta ferramenta de perfilagem é afetada por fatores externos como o peso do fluido e o diâmetro do poço. Ambos podem atenuar a radiação que é lida pelo sensor da ferramenta. Esses fatores são levados em consideração nas correções ambientais feitas pelas companhias de perfilagem (SCHLUMBERGER, 2015).

#### 4.2.7 Espectroscopia de raios gama natural

As ferramentas de raios gama espectrais empregam o mesmo sistema de detecção que os dispositivos de raios gama totais, no entanto, ao invés de usar uma região de ampla energia para detecção, os raios gama são analisados em uma série de diferentes fontes de energia determinada por qual elemento as emitiu. Cada um dos elementos radioativos de ocorrência natural padrão (K, U e Th) emite um raio gama de uma energia única quando se decompõe, assim, a calibração em formações padrão, onde as concentrações de K, U e Th são conhecidas, permite a determinação das concentrações destes elementos na formação analisada. (ELLIS; SINGER, 2008; SCHLUMBERGER, 2015).

A desvantagem das curvas espectrais de raios gama é que, ao dividir os espectros em três componentes, a taxa de contagem para qualquer componente pode ser menor que um terço da medição total devido a erros matemáticos e baixo sinal recebido. Se forem necessárias medições de raios gama espectrais de maior precisão, é necessária uma velocidade de registro reduzida.

#### 4.2.8 Espectroscopia de raios gama induzido

A sonda de espectroscopia de captura de raios gama utiliza uma fonte de emissão de nêutrons, provenientes de uma fonte química ou eletrônica, e detectores para medir os campos relativos elementares de interação dos nêutrons com os átomos da formação. Os elementos primários medidos são: silício (Si), ferro (Fe), cálcio (Ca), enxofre (S), titânio (Ti), gadolínio (Gd), cloro (Cl), bário (Ba) e hidrogénio (H) (SCHLUMBERGER, 2015).

Os nêutrons interagem com a formação e emitem radiação gama em diversas energias. A ferramenta lê, então, o espectro dessa emissão e é realizada posteriormente a deconvolução espectral deste em espectros elementares (H, O, Si, Ca, Mg, Fe, etc.) por meio de um conjunto de padrões elementares para se determinar composição elementar mássica (% m/m) dos elementos, o peso seco dos mesmos, litologia e propriedades da matriz.

Cada elemento possui uma seção de choque diferente. A contribuição de cada elemento no espectro total será impactada pela seção de choque e pela sua abundância na formação. Alguns elementos necessitam de aquisições específicas para aumentar a confiabilidade de sua leitura, como é o caso do Mg. Em seguida, é realizada a conversão em massa seca onde a leitura do espectro é adimensional e resultante da interação de todos os elementos químicos que compõem a rocha. Elementos considerados provenientes tanto do fluido quanto da rocha são desconsiderados (H, C, O, Cl) e os outros elementos são recalculados utilizando um modelo de óxidos (ELLIS; SINGER, 2008).

Esta técnica pode ser utilizada em poços revestidos, visto que os nêutrons conseguem passar pelo revestimento e fazer leituras da formação. Assim, é aplicada no acompanhamento da mudança do contato óleo/água ao longo do tempo em poços produtores através da informação de Carbono Orgânico Total (TOC).

#### 4.3 REDES NEURAIS ARTIFICIAIS

Para se minimizar subjetividades provenientes do processo de interpretação de dados, em especial em reservatórios carbonáticos, tem-se como alternativa a utilização de técnicas de análises multivariadas a partir de algoritmos de aprendizagem e inteligência artificial.

Técnicas de análise multivariada são métodos estatísticos que simultaneamente analisam múltiplas variáveis sobre cada objeto de investigação. O seu propósito é medir, explicar e prever o grau de relacionamento entre variáveis estatísticas. (RIBEIRO; LANDAU; SOARES, 2008).

Dentre os algoritmos de aprendizagem e inteligência artificial, destacam-se as técnicas de aprendizagem de máquina bio-inspiradas, como as redes neurais artificiais (RNAs), desenvolvidos para solucionar automaticamente complexos problemas de reconhecimento de padrões (KURODA, 2015). De acordo com (HAYKIN, 2001) uma rede neural é um processador constituído de unidades de processamento simples, também denominada neurônios, que têm a propensão para armazenar conhecimento adquirido de seu ambiente e torna-lo útil. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para o armazenamento deste conhecimento.

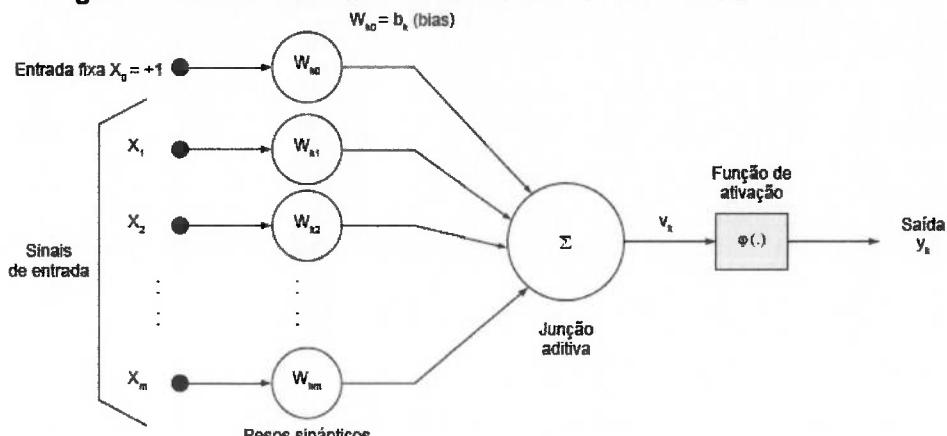
De um modo geral, os métodos de aprendizagem pode ser divididos entre supervisionado, quando a modificação dos pesos sinápticos provém do treinamento de uma regra em um conjunto de amostras para as quais se dispõe tanto das variáveis de entrada quanto da variável de saída; não-supervisionado, onde se dispõe apenas das variáveis de entrada e os pesos são definidos de modo a diminuir as diferenças entre os neurônios e o conjunto de entrada; e de reforço, no qual há uma função objetivo e os pesos são ajustados por meio de *feedbacks* positivos ou negativos a medida em que a rede é treinada. (HAYKIN, 2001).

As redes neurais artificiais são constituídas de três componentes principais: o neurônio, nó ou elemento de processamento, o peso da conexão e as camadas discretas que contêm os nós e são conectados pelos pesos (POULTON, 2001). O neurônio é a unidade computacional básica em uma rede e é classificado de acordo com seu papel na rede entre neurônio de entrada, saída e neurônios ocultos. Um neurônio de entrada recebe informações de uma fonte externa, como um arquivo de entrada e os transmite aos neurônios seguintes, contudo, eles não realizam nenhum

tipo de operação. Um neurônio que transmite seus valores calculados para uma fonte externa (arquivo de saída) é chamado de neurônio de saída. Qualquer outro neurônio que não esteja em uma camada de entrada ou saída é chamado de neurônio oculto, visto que não têm conexão direta com o “mundo externo”.

Na Figura 1 tem-se um exemplo simplificado de um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso sináptico, de uma rede neural supervisionada. Um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicado pelo sináptico  $w_{kj}$ . Os sinais de entrada são somados, ponderados pelas respectivas sinapses do neurônio, constituindo um combinador linear. Para restringir a amplitude da saída do neurônio tem-se uma função de ativação (HAYKIN, 2001).

**Figura 1** - Modelo não linear de um nó de uma rede neural artificial.



**Fonte:** (HAYKIN, 2001)

Atualmente já se utilizam redes neurais artificiais para a caracterização de formações e reservatórios antes e durante a produção (ASFAHANI; AHMAD; GHANI, 2018; POULTON, 2001), contudo, a abordagem mais recorrente na indústria do petróleo é supervisionada. Tais RNAs dependem de treinamento prévio, ou seja, necessitam de alguns dados de saída para estabelecer correlações com os dados de entrada, e somente são eficazes em pequenos intervalos de profundidade, visto que as oscilações de parâmetros são menores em pequenos trechos. Sendo assim, a interpretação de dados em novos campos ou em poços com características não semelhantes aos já conhecidos torna-se mais subjetiva e propensa a erros. Além disso, as RNAs supervisionadas não geram respostas se houver ausência de dados em um trecho, uma vantagem da técnica *Self Organizing Maps*, que estima dados faltantes e classifica todo o trecho do poço.

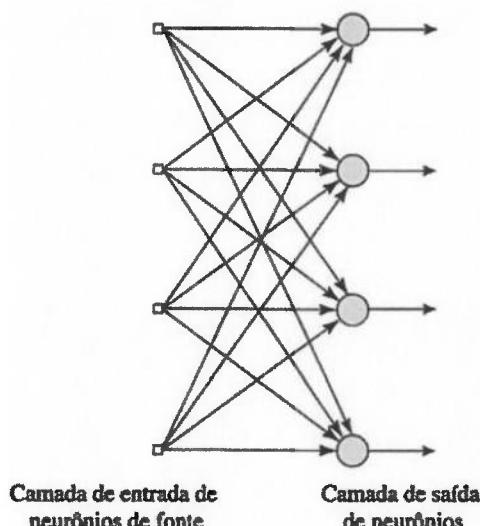
#### 4.4 SELF-ORGANIZING MAPS

*Self-Organizing Maps* (SOM) ou mapas auto-organizáveis são descritos como uma ferramenta de análise e visualização de dados n-dimensionais, com base nos princípios de quantização vetorial e medidas, em termos de distância euclidiana, do vetor similaridade (KOHONEN, 2001). Fraser e Dickson (2007) descrevem o SOM não somente como uma ferramenta exploratória de análise de dados, mas também como um método capaz de executar grandes categorias de operações, como previsão ou estimativa, agrupamento, classificação, reconhecimento de padrões e redução de ruído.

Tratando-se de um método não supervisionado, nenhum conhecimento prévio é necessário em relação à natureza ou ao número de agrupamentos no conjunto de dados (KOHONEN, 1997). Esta característica torna os mapas auto-organizáveis adaptáveis a diferentes tipos de dados, podendo ser um boa ferramenta de auxílio na caracterização petrofísica de dados com ausência ou escassez de identificação geológica (BHATT; HELLE, 2002; POULTON, 2001).

O algoritmo é constituído por duas camadas: a camada de entrada composta pelos dados de perfis a serem analisados e a camada de saída representada por uma malha formada por unidades computacionais interligadas, os neurônios. Essa rede é chamada de rede de camada única (Figura 2) visto que a camada de entrada não é considerada por não serem realizadas nesta qualquer computação (HAYKIN, 2001; KOHONEN, 2001).

**Figura 2** - Rede acíclica com única camada de neurônios.

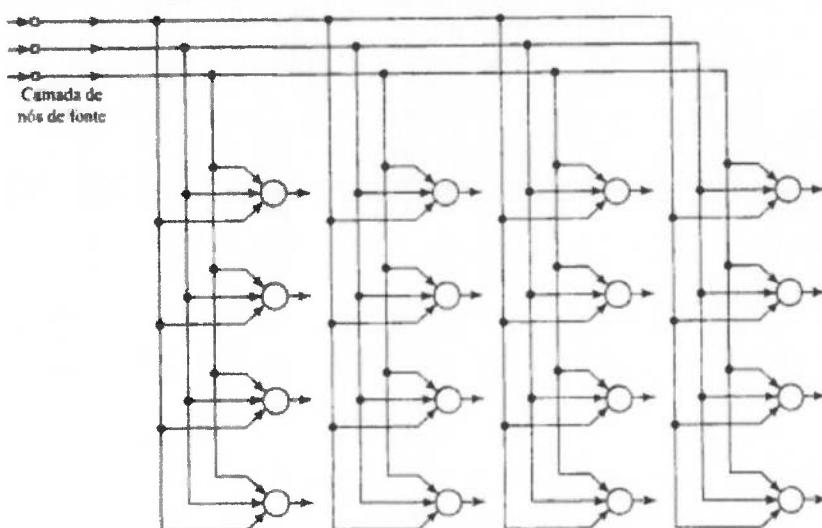


**Fonte:** (HAYKIN, 2001)

Os mapas auto-organizáveis, em sua forma básica, produzem um gráfico de similaridade dos dados de entrada. As relações estatísticas não-lineares entre dados de alta dimensão são convertidas em relações geométricas simples de seus pontos de imagem em uma exibição de baixa dimensão, geralmente uma grade bidimensional regular de nós (KOHONEN, 1997).

A Figura 3 mostra tal diagrama de neurônios, comumente utilizado como mapa discreto. Cada neurônio da grade está totalmente conectado com todos os nós de fonte da camada de entrada. Cada padrão de entrada apresentado à grade consiste em uma região localizada ou foco de atividade contra um fundo em repouso. Todos os neurônios da grade devem, portanto, ser expostos a um número suficiente de diferentes realizações do padrão de entrada para assegurar que o processo de auto-organização tenha uma chance de “amadurecer” (HAYKIN, 2001).

Figura 3 - Grade bidimensional de neurônios.



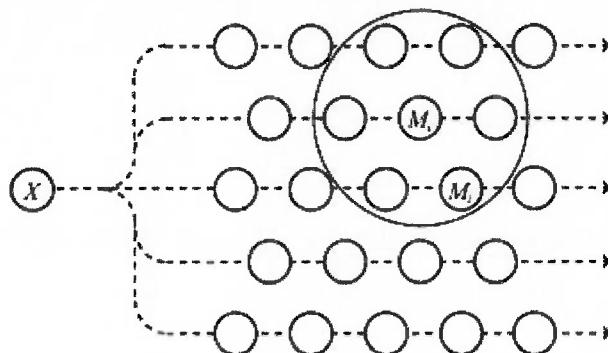
Fonte: (HAYKIN, 2001)

O primeiro passo realizado pelo algoritmo responsável pela formação do mapa auto-organizável é a inicialização dos pesos sinápticos da grade. Isso pode ser feito atribuindo-lhes valores pequenos tomados de um gerador de números aleatórios. Após a inicialização da grade, são realizados três processos iniciais: competição, cooperação e adaptação sináptica. Primeiramente, para cada padrão de entrada, os neurônios da grade calculam seus respectivos valores de uma função discriminante. O neurônio com o maior valor desta função é ativado. Apenas um neurônio de saída, que tem a distância euclidiana mínima entre ele e o padrão de entrada, é selecionado. Este neurônio ativado é chamado de *best matching unit* (BMU). O

neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, fornecendo base para a cooperação entre neurônios vizinhos. O último mecanismo permite que os neurônios excitados aumentem seus valores individuais da função discriminante em relação ao padrão de entrada através de ajustes adequados aplicados a seus pesos sinápticos (HAYKIN, 2001; KOHONEN, 1997).

A Figura 4 exemplifica de maneira simplificada o algoritmo descrito. Neste caso, um dado  $X$  de entrada é inserido e transmitido para um conjunto de modelos  $M_i$ .  $M_c$  trata-se do modelo que melhor combina com o vetor  $X$ . Todos os modelos que estão na vizinhança (círculo maior) de  $M_c$  na grade são readjustados de modo a melhor combinarem com  $X$ .

**Figura 4- Ilustração do algoritmo do SOM.**



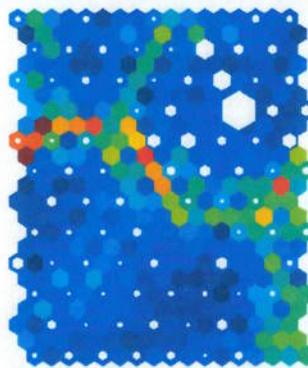
**Fonte:** (KOHONEN, 2013)

O fato de os neurônios vizinhos também se ajustarem para se tornarem mais semelhantes ao padrão de treinamento permite que os vetores de saída se tornem topologicamente ordenados e que as relações entre as amostras sejam preservadas.

Após o ajuste destes vetores, todas as amostras originais podem ser representadas tanto em planos quanto em formas tridimensionais, como em um toróide, e estas então são rebatidas para um mapa 2D denominado “matriz unificada de distâncias” (matriz U). Esta matriz indica as relações de proximidade e vizinhança entre os neurônios no mapa projetado, desenvolvidas por meio de uma escala de cores. Dessa maneira, as cores frias (azul) indicam maior similaridade, representada pela menor distância entre os neurônios vizinhos, e as cores quentes (vermelho), indicam menor similaridade, dada a maior distância entre os neurônios vizinhos. A

Figura 5 ilustra uma matriz U típica em que os hexágonos representam as entradas e o tamanho desses é proporcional ao número de amostras que este representa.

**Figura 5-** Exemplo de matriz U gerada em mapa tamanho 12 x 09.



Fonte: SPADA (2016)

Além da matriz U, o SOM apresenta como saída parcelas componentes de cada uma das características de entrada, BMU's para cada amostra e variável analisada e erro de quantização (QER). As parcelas componentes (*component plots*) indicam a influência de cada variável nos grupos de amostras. Como cada nó é um vetor no espaço de dados definido pelas variáveis de entrada, é possível visualizar a contribuição de cada nó para uma variável específica e exibir os valores, novamente usando uma escala de temperatura de cor, em que valores baixos são exibidos em azul e valores altos em vermelho. Já o QER representa uma medida da distância que uma amostra tem de seu *node-vector*. Amostras com alto erro de quantização representam valores discrepantes em um conjunto de dados (FRASER; DICKSON, 2007).

## 5 MATERIAIS E MÉTODOS

### 5.1 MATERIAIS

Para o desenvolvimento deste projeto serão utilizados dados de perfis de poços do acervo do Banco de Dados de Exploração e Produção (BDEP) criado pela Agência Nacional de Petróleo (ANP) com a finalidade de conferir transparência as informações e facilitar o desenvolvimento de pesquisas e trabalhos relacionados as bacias sedimentares brasileiras.

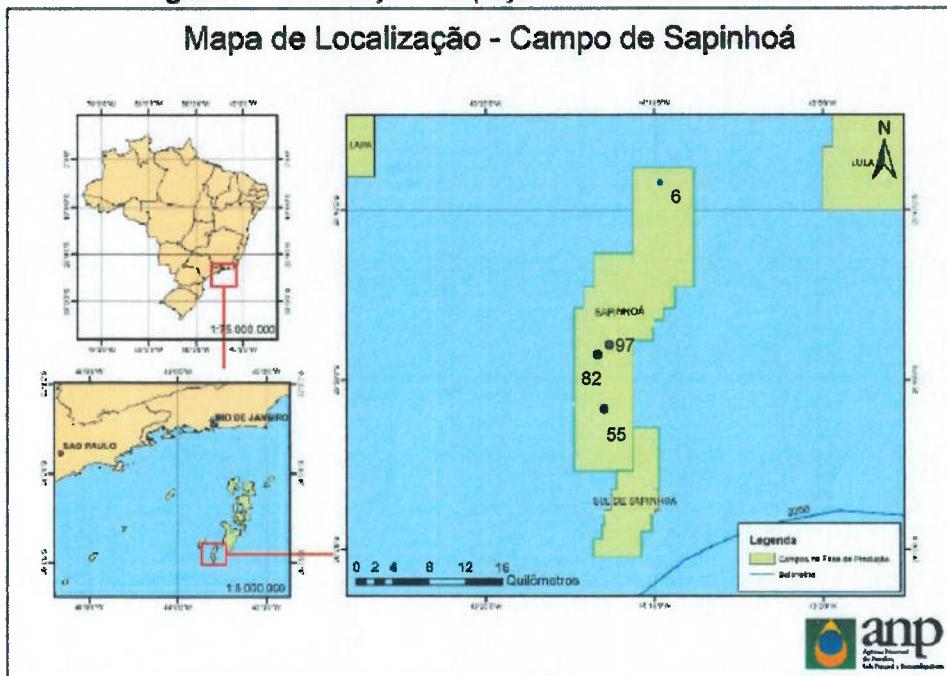
Tais dados serão avaliados com apoio do software *Interactive Petrophysics*, IP®, e posteriormente as análises serão realizadas utilizando-se o software *SiroSOM*®.

Como variáveis de entrada serão utilizados perfis de quatro diferentes poços localizados na bacia de Santos dispostos conforme a Figura 6. Os trechos

analisados possuem 12" de diâmetro, foram perfurados com fluido base óleo e a água de formação possui salinidade em torno de 200.000ppm de NaCl.

Os perfis corridos em cada poço e suas especificações, retiradas do catálogo de ferramentas da Schlumberger (SCHLUMBERGER, 2015) estão indicados na Tabela 1.

**Figura 6 – Localização dos poços utilizados nas análises.**



**Fonte:** Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (2017)- modificada.

**Tabela 1- Descrição das ferramentas utilizadas para cada perfil.**

Perfil	Ferramenta	Faixa de medição	Profundidade de investigação	Resolução vertical
Raios Gama	HGNS	0 a 1,000 gAPI	60.96 cm	30.48 cm
Raios Gama espectral	NGS	0 a 2,000 gAPI	24.13 cm	20.32 a 30.48 cm
Raios Gama Induzido	ECS	45.72 cm	22.86 cm	45.72 cm
Resistividade	AIT-M	0.1 a 2,000 ohm.m	AT10: 25.40 cm AT20: 50.80 cm AT30: 76.20 cm AT60: 152.40 cm AT90: 228.60 cm	0.30, 0.61, e 1.22 m
Sônico	SonicScanner	<4,920 us/m	Até 7x raio do poço	

Perfil	Ferramenta	Faixa de medição	Profundidade de investigação	Resolução vertical
<b>Densidade</b>	TLD	1.04 a 3.3 g/cm <sup>3</sup>	12.70 cm	45.72 cm
<b>Efeito Fotoelétrico</b>	TLD	0.9 a 10	12.70 cm	-
<b>Caliper</b>	TLD	22 in	12.70 cm	-
<b>Neutrônico</b>	HGNS	0 a 60 pu [porosidade não corrigida]	23 cm	30.48 cm
<b>Ressonância Magnética</b>	CMR-Plus	Porosidade: 0-100 pu Mínimo espaçamento de eco: 200 us T2: 0.3 ms a 3.0 s Sinal/ruído: 32 dB	Zona cega (2.5%): 1.27 cm Média (50%): 2.84 cm Máximo (95%): 3.81 cm	Estática: 15.24 cm Dinâmica: Alta resolução: 22.86cm intermediária: 45.72cm modo rápido: 76.20cm

## 5.2 MÉTODOS

Visando a classificação das amostras utilizou-se a rotina proposta por Carneiro et al. (2012) para classificação de dados geológicos. No entanto, neste trabalho, foi necessária uma adaptação para as variáveis relacionadas à reservatórios de petróleo.

### 5.2.1 Definição dos parâmetros de entrada

O primeiro parâmetro a se definir é o espaço n-dimensional onde se encontram as amostras. Esse número determina o tamanho do mapa de saída e, consequentemente, o número de vetores semente que serão treinados para representar a distribuição original de amostras no espaço de dados. De acordo com Vesanto et al. (2000), o tamanho do mapa pode ser calculado a partir da Equação 1:

$$\text{Tamanho do mapa} = 5 \times \sqrt{\text{número de amostras}} \quad (1)$$

O número de amostras, neste caso, representa o número de pontos amostrados pelos perfis. Como cada perfil apresenta uma resolução, todos foram plotados no IP, que realiza a interpolação entre os pontos de perfis menor resolução. Os perfis foram, então, exportados de modo que as amostras apresentassem um passo regular. Os trechos escolhidos para análise tinham amostras para todas as variáveis, em todas as profundidades. A Tabela 2 relaciona o número de amostra de cada poço e o tamanho do mapa utilizado.

**Tabela 2 - Tamanho do mapa para cada caso.**

	<b>Número de amostras</b>	<b>Tamanho do mapa</b>	<b>Número de linhas do mapa</b>	<b>Número de colunas do mapa</b>
<b>Poço 6</b>	2988	273	20	14
<b>Poço 55</b>	2503	250	18	14
<b>Poço 82</b>	5019	354	22	16
<b>Poço 97</b>	2900	269	18	15
<b>Todos</b>	11540	579	26	21

Para as análises, foi utilizada a inicialização randômica dos pesos sinápticos, uma grade hexagonal foi escolhida como formato de visualização e a superfície de um hipervolume toroidal utilizada para a projeção dos neurônios ou BMU's, de forma que seja possível a melhor visualização espacial da semelhança entre os dados e para que a topografia seja preservada.

Outros parâmetros definidos para a rede são descritos na tabela abaixo (Tabela 3).

**Tabela 3- Parâmetros de entrada SOM.**

	<b>Ajuste grosso</b>	<b>Ajuste fino</b>
<b>Raio da vizinhança - inicial</b>	34	9
<b>Raio da vizinhança - final</b>	9	1
<b>Comprimento de treino</b>	20	400

### **5.2.2 Descrição do procedimento**

Os dados foram analisados e preparados utilizando-se a plataforma IP® e posteriormente formatados para a leitura vetorial das amostras analisadas. Cada amostra representa uma profundidade de medição e apresenta um valor para cada uma das variáveis inseridas nas análises, neste caso, os perfis de poços.

Em um primeiro momento, todas as variáveis foram inseridas no ambiente SOM visando analisar a interdependência entre os perfis por meio da análise do coeficiente de determinação. Com base nesses resultados os perfis que apresentaram índice de correlação menor que 0,01 e maior que 0,99 foram suprimidos por interferir de forma negativa na clusterização. A tabela com os dados selecionados foi, então, novamente introduzida na plataforma SOM.

Após o ajuste dos vetores, todas as amostras originais foram representadas em um mapa 2D onde as relações (topografia) entre as amostras são preservadas (matriz U). Obteve-se também como saída do processamento as parcelas componentes de cada perfil e os *best-matching value* de cada curva (BMU).

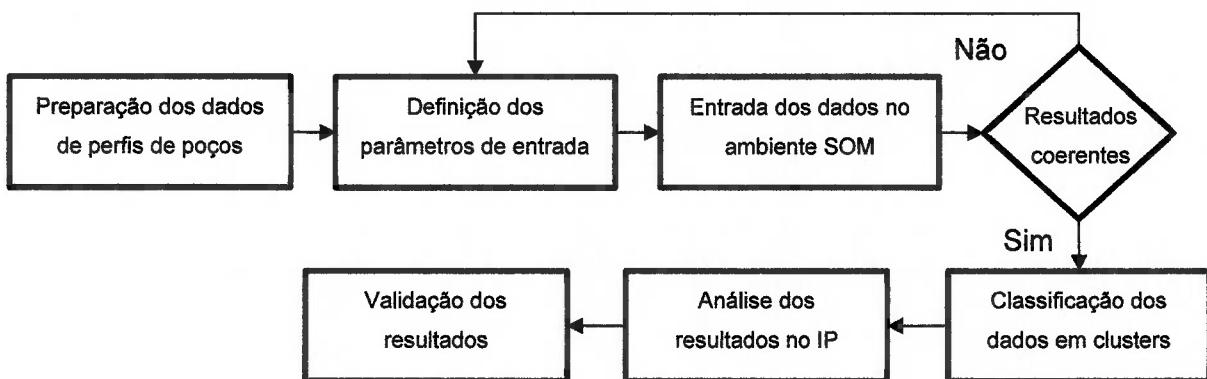
Cada neurônio ou BMU no mapa auto organizável representa um “mini-cluster” das variáveis de entrada. No entanto, para entender o comportamento destes neurônios em grupamentos maiores, é necessário realizar uma segunda classificação, desta vez, entre os neurônios resultantes do mapa-auto organizável.

A classificação dos neurônios resultantes se deu a partir da média-K, baseando-se no número de classes determinadas pelas análises de Davies e Bouldin (1979). Como resultados, obteve-se a clusterização dos dados a partir do mapa de similaridade entre as amostras permitindo, assim, a separação de amostras conforme suas características de similaridade natural.

Uma segunda análise foi realizada visando a classificação de zonas com maior permopermeabilidade. Para isso foram utilizados apenas os perfis de resistividade e neutrônico. O processamento foi executado de maneira similar ao processamento da primeira análise.

Os procedimentos descritos para cada uma das análises podem ser mais bem visualizados no fluxograma representado a seguir (Figura 7).

Figura 7 - Fluxograma dos procedimentos realizados.



### 5.2.3 Validação da metodologia de classificação litológica

Após a classificação dos tipos litológicos por meio da metodologia descrita os resultados foram comparados com a descrição realizada de maneira tradicional de interpretação visual realizada por geólogos. Este tipo de interpretação é realizado de

maneira mais superficial, sendo possível separar as rochas em grandes grupos, como por exemplo rochas carbonáticas, siliciclásticas e vulcânicas.

No procedimento de validação foram comparados o número de litologias diferentes presentes nos trechos analisados, os tipos litológicos e a distribuição dos mesmos ao longo dos poços. Comparou-se ainda se a técnica conseguiria identificar as diferentes formações presentes, Barra Velha e Itapema.

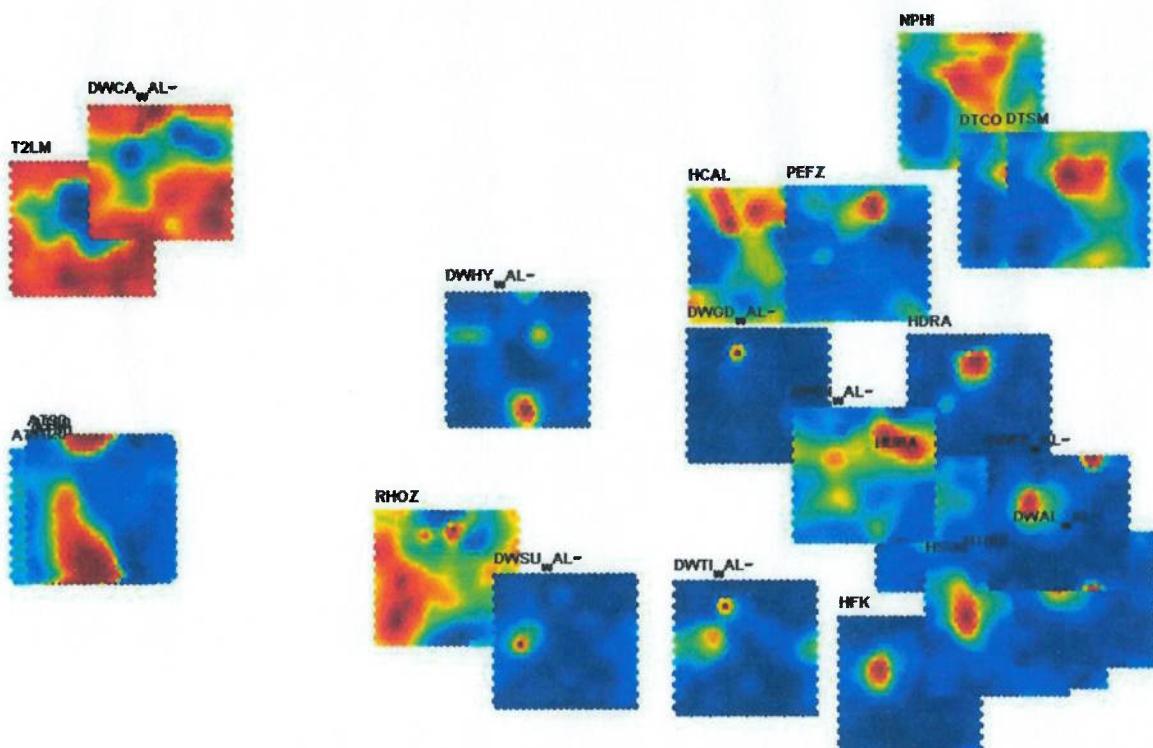
Uma segunda comparação foi feita com base em amostras laterais colhidas a intervalos regulares nos quatro poços. Esta, porém, é de mais difícil correlação devido ao número reduzido de amostras e a diferença de escala dos dados. Sendo assim, existe um alto grau de detalhamento dentro dos carbonatos, o que, muitas vezes, tem caráter interpretativo, como ambiente deposicional, e nem sempre se traduz em características petrofísicas que influenciam os perfis.

## 6 RESULTADOS E DISCUSSÕES

### 6.1 PREPARAÇÃO DOS DADOS PARA A SEPARAÇÃO LITOLÓGICA

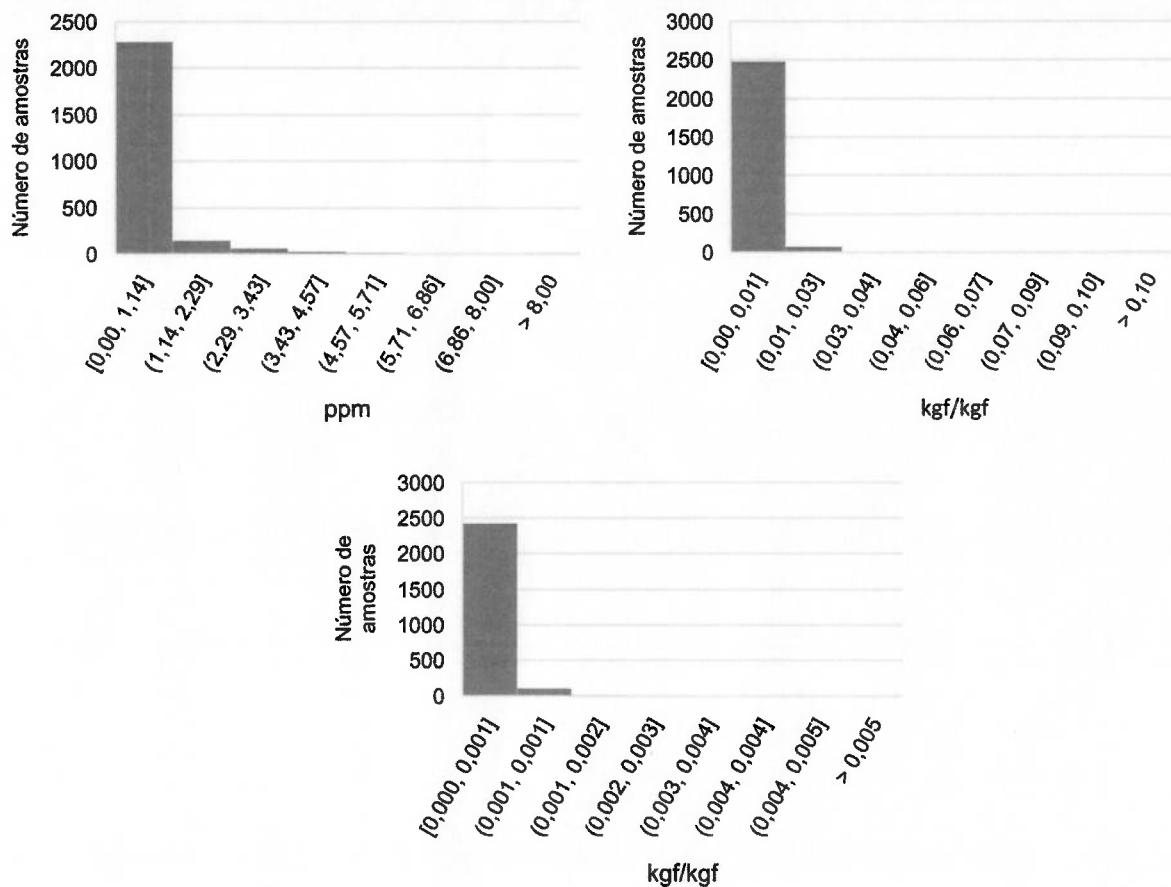
Realizado o processamento dos dados de todos os poços simultaneamente obteve-se a correlação entre as variáveis. Tais correlações podem ser visualizadas através da análise dos principais componentes (Figura 8). Nesta, os perfis em regiões mais próximas indicam elevado índice de correlação enquanto perfis mais distantes entre si, indicam baixa correlação. Quanto maior a correlação entre perfis, mais redundante se torna a informação, o que é prejudicial à análise. Visto que este é o caso dos perfis de resistividade (AT10, AT20, AT30, AT60 e AT90) estes foram retirados da primeira análise.

Figura 8 – Análise dos principais componentes aplicada aos neurônios.



Além disso, os dados relativos à quantidade de gadolínio, enxofre e titânio foram também retirados da análise devido à baixa quantidade destes componentes frente aos demais (alumínio, ferro, cálcio e silício), como pode ser visto nos histogramas abaixo (Figura 9). Estes valores ficam dentro da faixa de ruído dos perfis, o que torna o dado pouco confiável.

**Figura 9 - Histograma de distribuição de quantidade de gadolínio, enxofre e titânio, respectivamente.**



## 6.2 DEFINIÇÃO DE DIFERENTES LITOLOGIAS

A matriz  $U$  obtida é representada na Figura 10 de modo que a escala de cores indica as semelhanças entre nós adjacentes no mapa da seguinte maneira: as cores frias (azul) indicam grande similaridade entre os nós adjacentes e as cores quentes (vermelho) menor similaridade. Pode-se notar, na região delimitada em vermelho na Figura 11, que trata de um recorte da matriz  $U$ , uma zona com alta dissimilaridade, ou seja, amostras com características muito diferentes entre si, enquanto na região delimitada em amarelo há homogeneidade entre as amostras.

A partir destas zonas de similaridade e dissimilaridade as amostras foram agrupadas em grupos ou *clusters*. Como resultado da primeira análise obteve-se um número ótimo de cinco *clusters*, ou seja, cinco classes litológicas (Figura 10).

Figura 10 – Matriz U obtida por mapa 26x21 (à esquerda) e clusters obtidos (à direita).

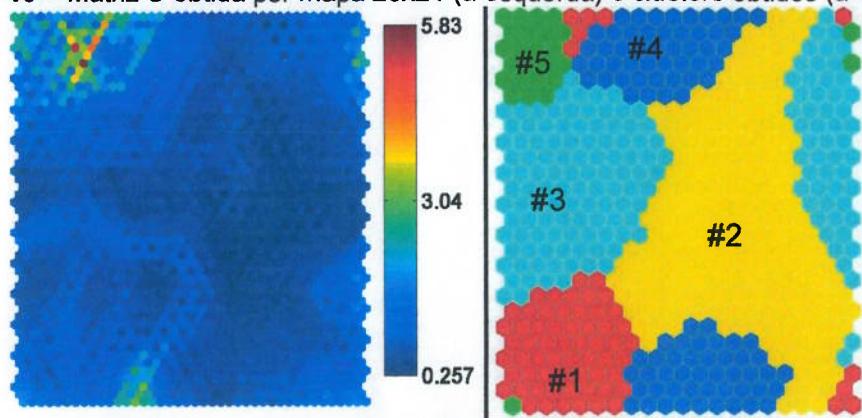
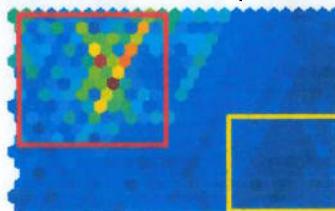
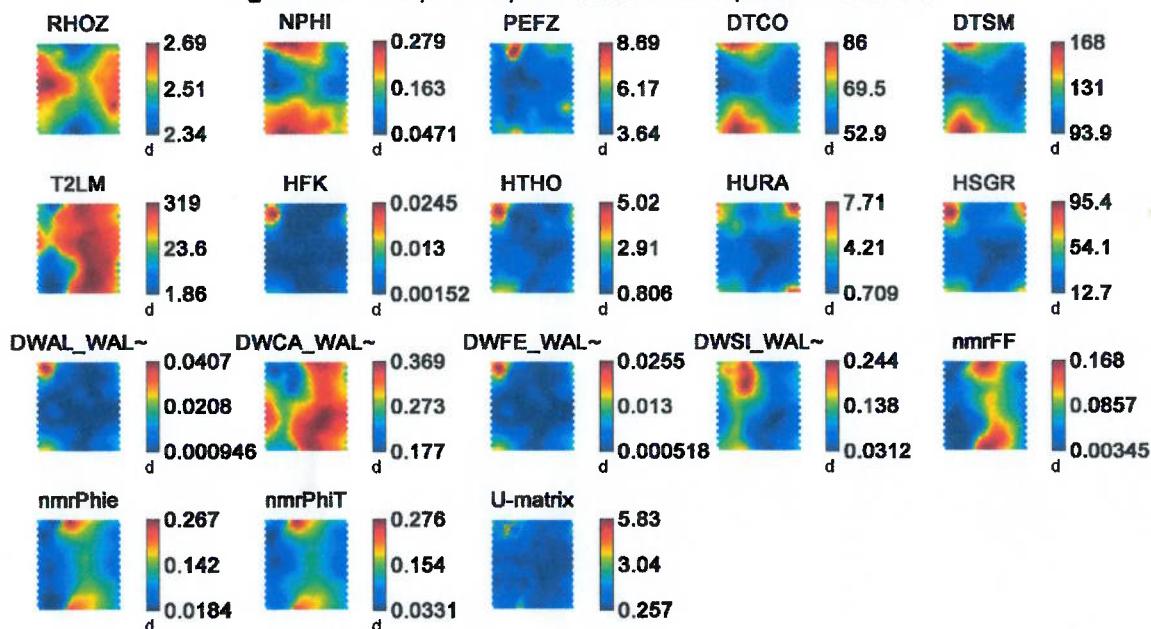


Figura 11 - Grau de similaridade representado na matriz U.



Cada variável influí para a geração desta matriz U já que, para cada par de amostras, tem-se variáveis semelhantes ou distintas. Como cada nó é um vetor no espaço definido por cada variável é possível visualizar a contribuição de cada variável através da mesma escala de temperatura de cores da matriz U. Essa influência é representada na Figura 12 por meio de *component plots*.

Figura 12 - Component plots baseado nos perfis de entrada.



Comparando a intensidade de cada uma das variáveis ao resultado visualizado na matriz U, pode-se verificar grande influência do perfil neutrônico (NPHI) e sônicos

(DTCO e DTSM) nos *clusters* 1, 3, 4 e 5 onde tem-se valores baixos nos *clusters* 3 e 5 e elevados nos *clusters* 1 e 4. Nota-se também grande influência dos perfis de ressonância magnética nuclear (nmrFF, nmrPhie e nmrPhiT) no *cluster* 4, assim como dos perfis de raios gama natural (HFK, HTHO e HURA) no *cluster* 5. O *cluster* 2 não tem influência predominante de nenhum dos perfis e sim do conjunto.

Para tornar esta análise mais precisa, analisou-se quantitativamente os dados de cada variável. Determinou-se três faixas de valores para cada perfil (Tabela 4) buscando avaliar as características de cada *cluster* em relação a cada uma das variáveis. As médias de valores de cada perfil por *cluster* são representadas na Tabela 5.

**Tabela 4 - Faixa de valores para cada variável por cluster.**

Perfis	baixo	Médio	alto
RHOZ	< 2,50	2,50 < x < 2,62	> 2,62
NPHI	< 0,15	0,15 < x < 0,20	> 0,20
PEFZ	< 4,95	4,95 < x < 7,42	> 7,42
DTCO	< 62,40	62,40 < x < 70,81	> 70,81
DTSM	< 122,84	122,84 < x < 141,15	> 141,15
T2LM	< 100,00	100,00 < x < 200,00	> 200,00
HFK	< 0,013	0,013 < x < 0,026	> 0,026
HTHO	< 2,25	2,25 < x < 4,04	> 4,04
HURA	< 4,08	4,08 < x < 7,92	> 7,92
HSGR	< 47,81	47,81 < x < 88,15	> 88,15
DWAL_WAL	< 0,01	0,01 < x < 0,03	> 0,03
DWCA_WAL	< 0,17	0,17 < x < 0,28	> 0,28
DWFE_WAL	< 0,01	0,01 < x < 0,03	> 0,03
DWSI_WAL	< 0,15	0,15 < x < 0,27	> 0,27
nmrFF	< 0,09	0,09 < x < 0,15	> 0,15
nmrPhie	< 0,09	0,09 < x < 0,15	> 0,15
nmrPhiT	< 0,09	0,09 < x < 0,15	> 0,15

**Tabela 5 - Características médias de cada cluster.**

cluster	1	2	3	4	5
RHOZ	2,52	2,54	2,61	2,42	2,56
NPHI	0,23	0,16	0,11	0,22	0,14
PEFZ	5,06	4,70	4,34	5,31	4,76
DTCO	76,93	62,53	59,13	71,01	65,82
DTSM	145,95	112,82	105,68	129,24	117,56
T2LM	6,39	202,67	102,22	228,54	21,29
HFK	0,005	0,002	0,003	0,002	0,019
HTHO	2,33	1,27	1,46	1,06	4,19
HURA	3,08	1,73	2,39	2,12	4,80

<b>HSGR</b>	39,89	23,91	30,48	25,08	85,26
<b>DWAL_WAL~</b>	0,013	0,003	0,004	0,004	0,031
<b>DWCA_WAL~</b>	0,27	0,33	0,29	0,31	0,21
<b>DWFE_WAL~</b>	0,008	0,002	0,003	0,002	0,019
<b>DWSI_WAL~</b>	0,13	0,07	0,12	0,10	0,16
<b>nmrFF</b>	0,01	0,08	0,04	0,13	0,01
<b>nmrPhie</b>	0,04	0,11	0,07	0,17	0,04
<b>nmrPhiT</b>	0,09	0,12	0,08	0,18	0,06

Com base nos dados apresentados acima elaborou-se a Tabela 6, buscando tornar mais fácil a interpretação e identificação das características de cada um dos clusters.

**Tabela 6 – Aplicação das faixas de classificação nos valores médios de cada variável.**

<b>Cluster</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>
<b>RHOZ</b>	médio	médio	médio	baixo	médio
<b>NPHI</b>	alto	médio	baixo	alto	baixo
<b>PEFZ</b>	médio	baixo	baixo	médio	baixo
<b>DTCO</b>	alto	médio	baixo	alto	médio
<b>DTSM</b>	alto	baixo	baixo	médio	baixo
<b>T2LM</b>	baixo	alto	médio	alto	baixo
<b>HFK</b>	baixo	baixo	baixo	baixo	médio
<b>HTHO</b>	médio	baixo	baixo	baixo	alto
<b>HURA</b>	baixo	baixo	baixo	baixo	médio
<b>HSGR</b>	baixo	baixo	baixo	baixo	médio
<b>DWAL_WAL</b>	médio	baixo	baixo	baixo	alto
<b>DWCA_WAL</b>	médio	alto	alto	alto	médio
<b>DWFE_WAL</b>	baixo	baixo	baixo	baixo	médio
<b>DWSI_WAL</b>	médio	médio	médio	médio	médio
<b>nmrFF</b>	baixo	baixo	baixo	médio	baixo
<b>nmrPhie</b>	baixo	médio	baixo	alto	baixo
<b>nmrPhiT</b>	médio	médio	baixo	alto	baixo

Como podemos verificar, o cluster 4 é o grupo que apresenta litologias de menor densidade e alta porosidade. Já os clusters 1 e 5 são diferenciados dos demais devido a uma maior quantidade de tório, sendo esta ainda mais elevada no cluster 5. Este último apresenta também elevado teor de potássio levando a associação deste tipo litológico com argilominerais presentes no Pré-sal. As características do cluster 1 se assemelham às argilas magnesianas. Os clusters 2 e 3 apresentam característica bem semelhantes entre si tornando mais difícil a identificação litológica.

## 6.3 VALIDAÇÃO DOS RESULTADOS LITOLÓGICOS

### 6.3.1 Comparação com interpretação de geólogos

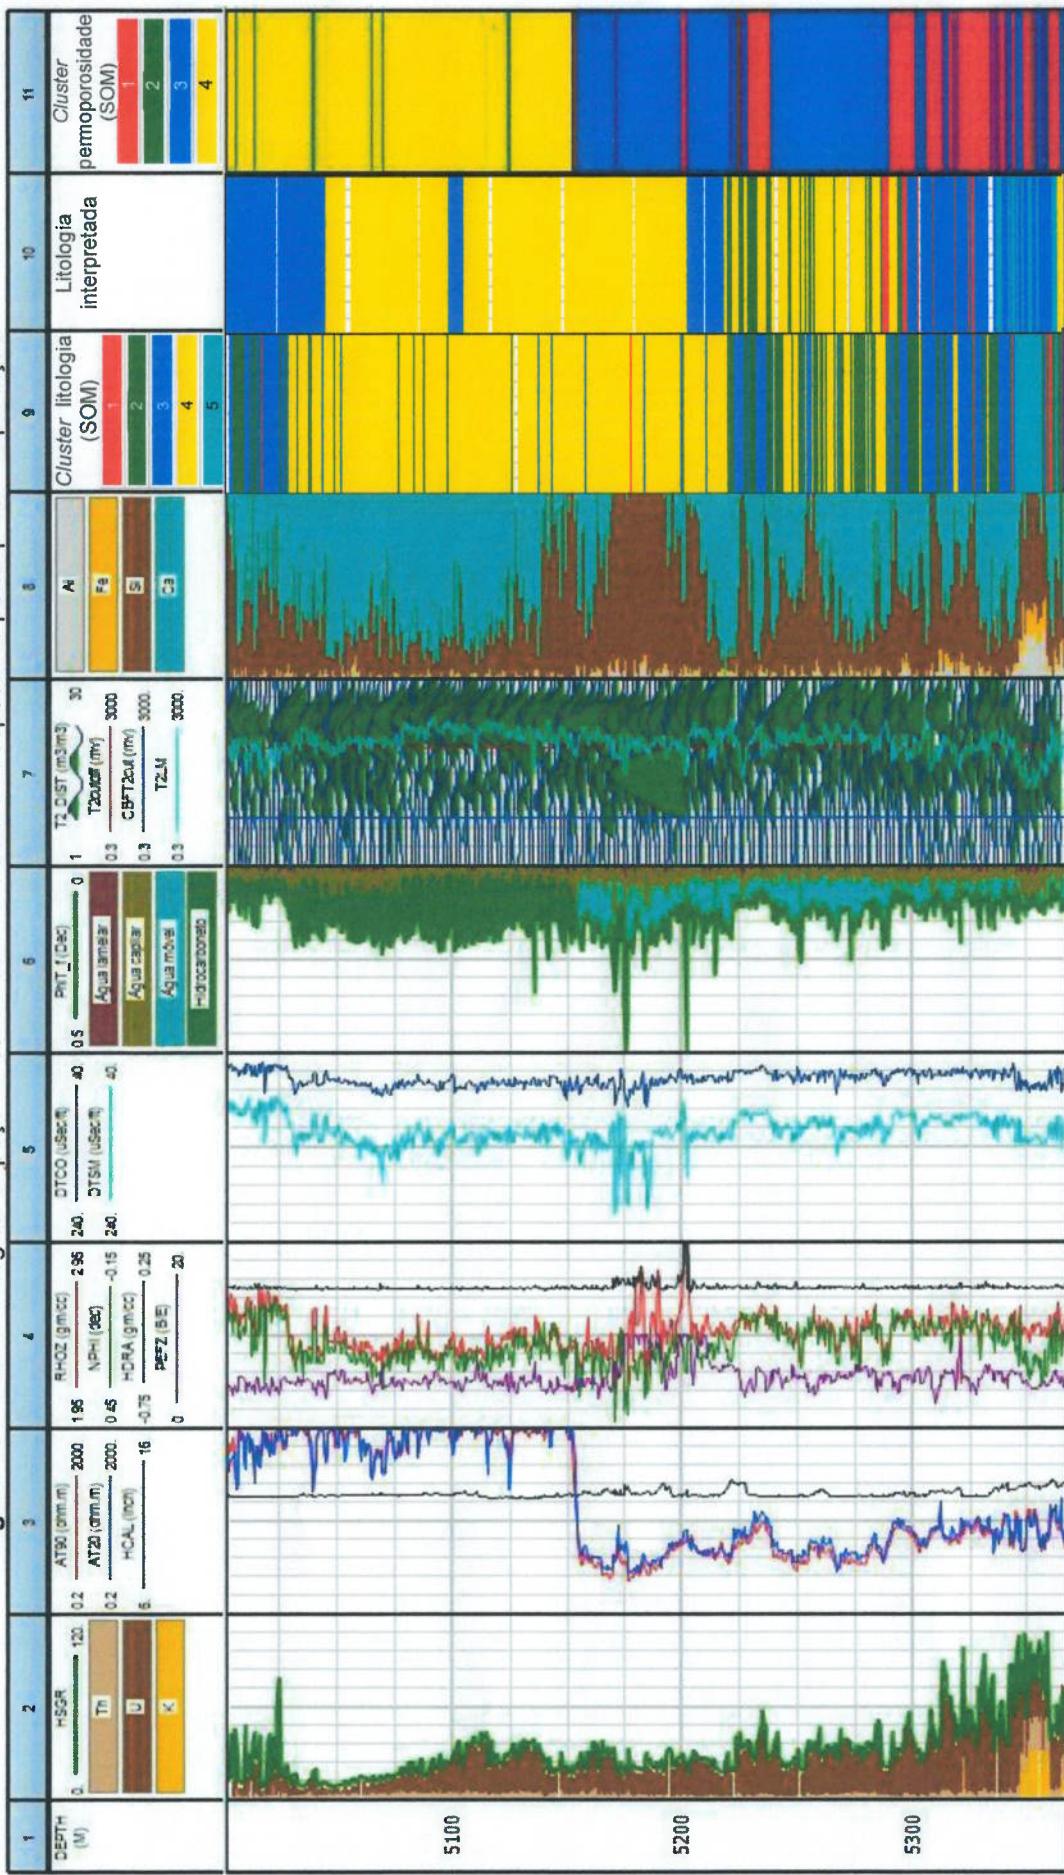
Com o objetivo de validar os resultados obtidos por meio do processamento através do SOM comparou-se estes com a interpretação realizada por geólogos de maneira visual. Inicialmente os perfis foram plotados no IP® assim como os clusters gerados buscando tornar mais visual a análise das faixas de valores de cada perfil. As figuras Figura 13, Figura 14, Figura 15 e Figura 16 contém tais resultados, sendo que a coluna 9 é referente às diferentes litologias provenientes da metodologia aplicada.

De maneira geral nota-se uma predominância das cores azul e amarelo, referentes, respectivamente, aos *clusters* 3 e 4. Essas litologias são descritas como carbonatos na interpretação visual contudo há uma diferenciação destas no resultado da técnica SOM. Os trechos em verde, que aparecem de forma mais recorrente no fundo dos poços, estão relacionados a marga e apresentam alta correspondência entre as interpretações.

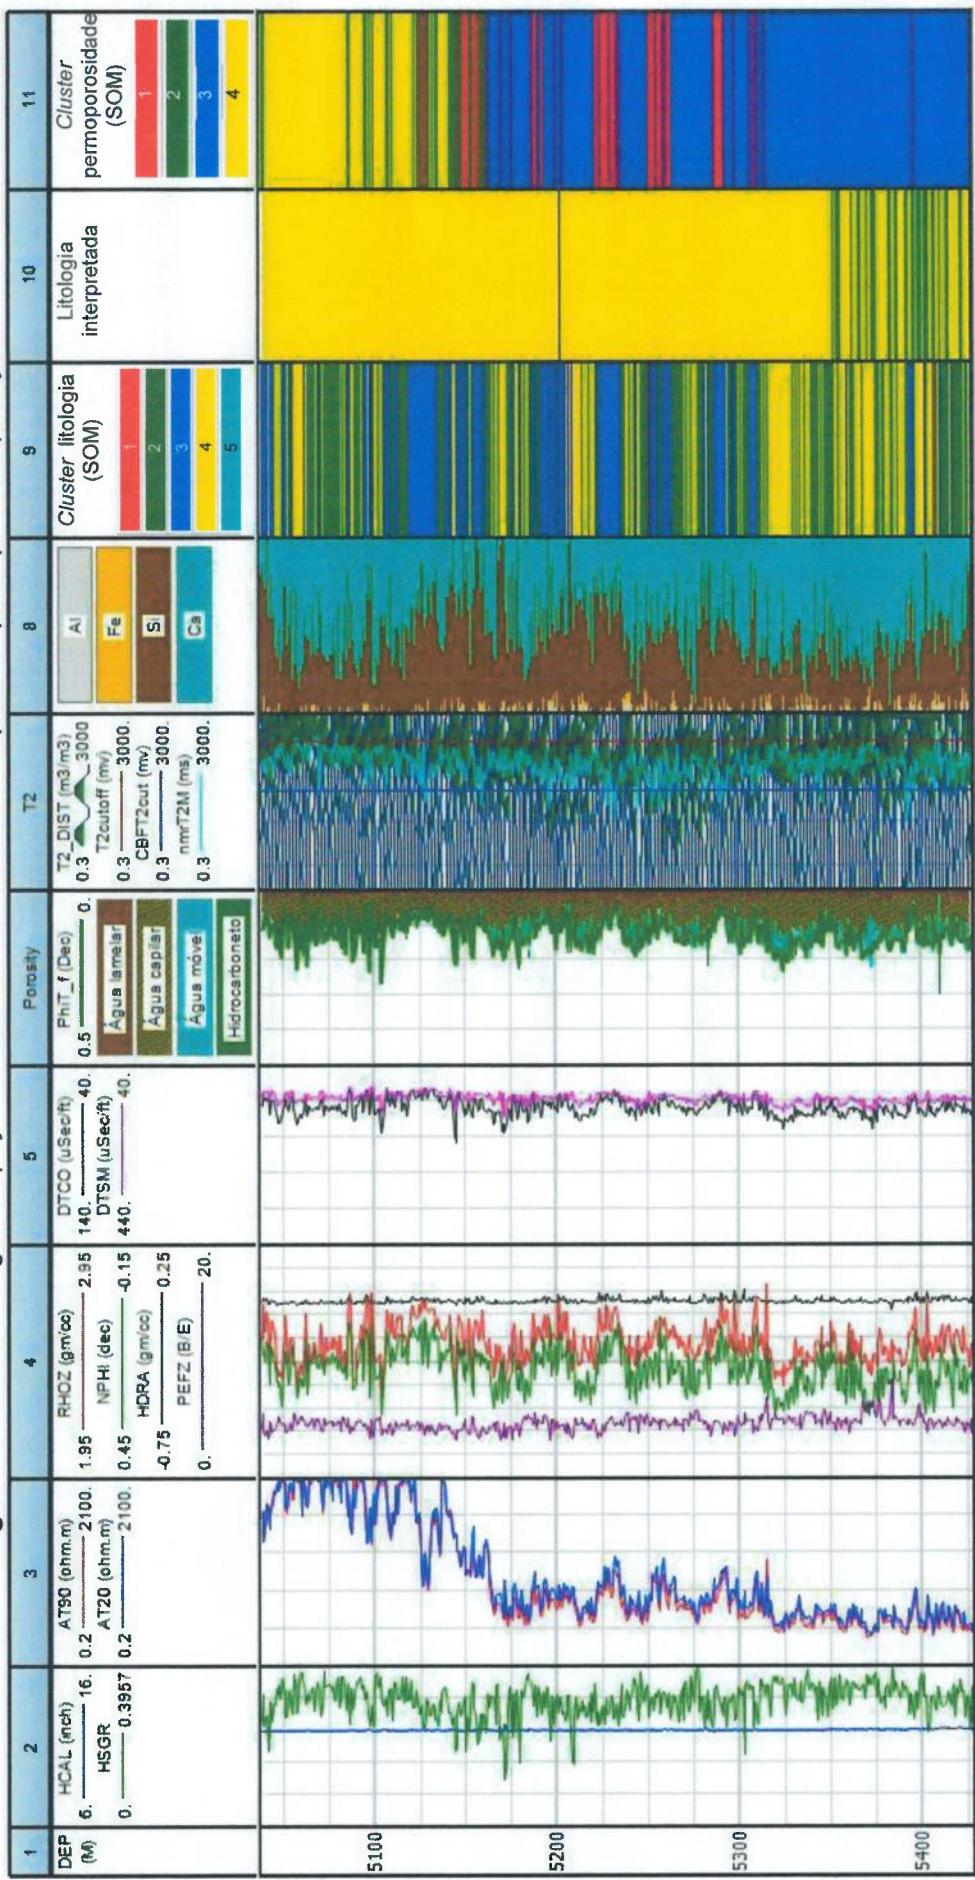
Pode-se notar, em especial no poço 82 (Figura 15), que a coloração vermelha é referente ao *cluster* 1 e a azul claro ao *cluster* 5, ou seja, as litologias marcadas em vermelho indicam argilas magnesianas, o que pode ser confirmado no aumento de água lamelar na coluna *Porosity*, enquanto as marcadas em azul claro, lamitos, comparando a elevação de potássio e tório na coluna 2. Estas litologias foram facilmente identificadas pelo SOM e correspondem ao resultado de interpretação visual por geólogos.

Em seguida, notou-se que os lamitos presentes na parte inferior dos poços 6 e 82 podem indicar o topo da formação Itapema e base da formação Barra Velha, que são as formações atravessadas pelos trechos de poços trabalhados. As profundidades em que essas rochas são indicadas nos perfis conferem com a análise geológica.

Figura 13 – Coluna litológica do poço 06 contendo os 5 clusters e respectivos perfis para interpretação.



**Figura 14 - Coluna litológica do poço 55 contendo os 5 clusters e respectivos perfis para interpretação.**



**Figura 15 - Coluna litológica do poço 82 contendo os 5 clusters e respectivos perfis para interpretação.**

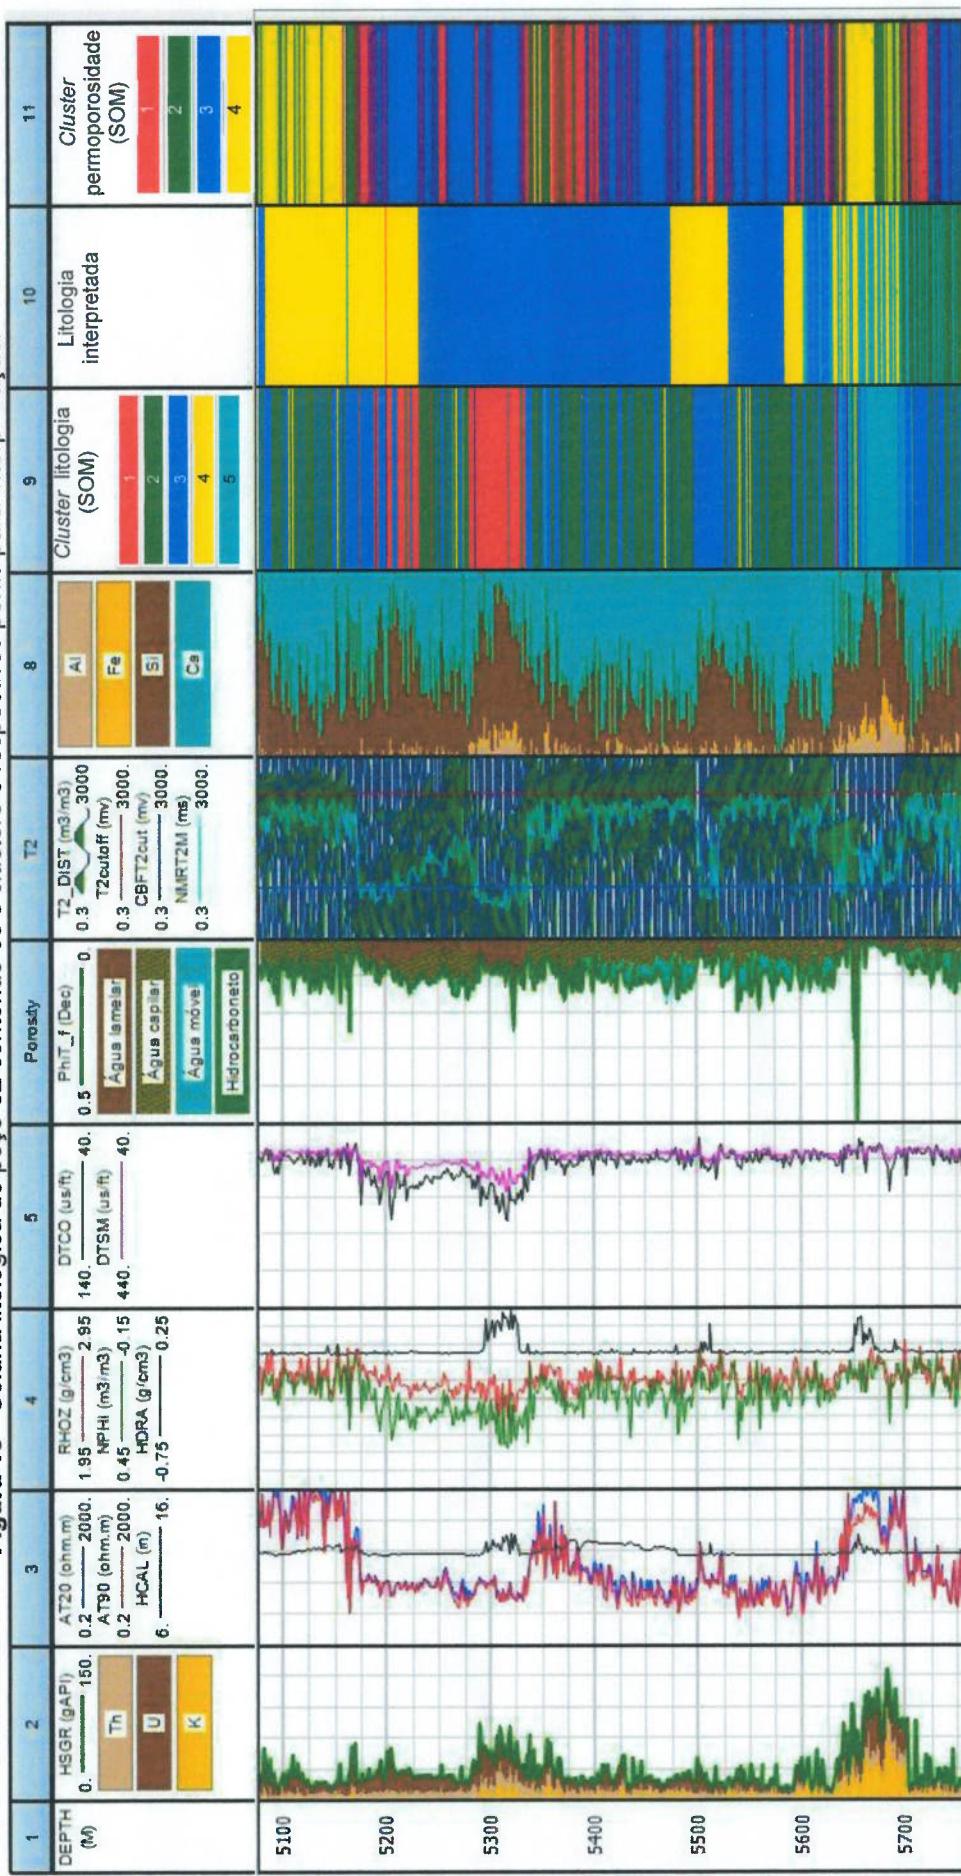
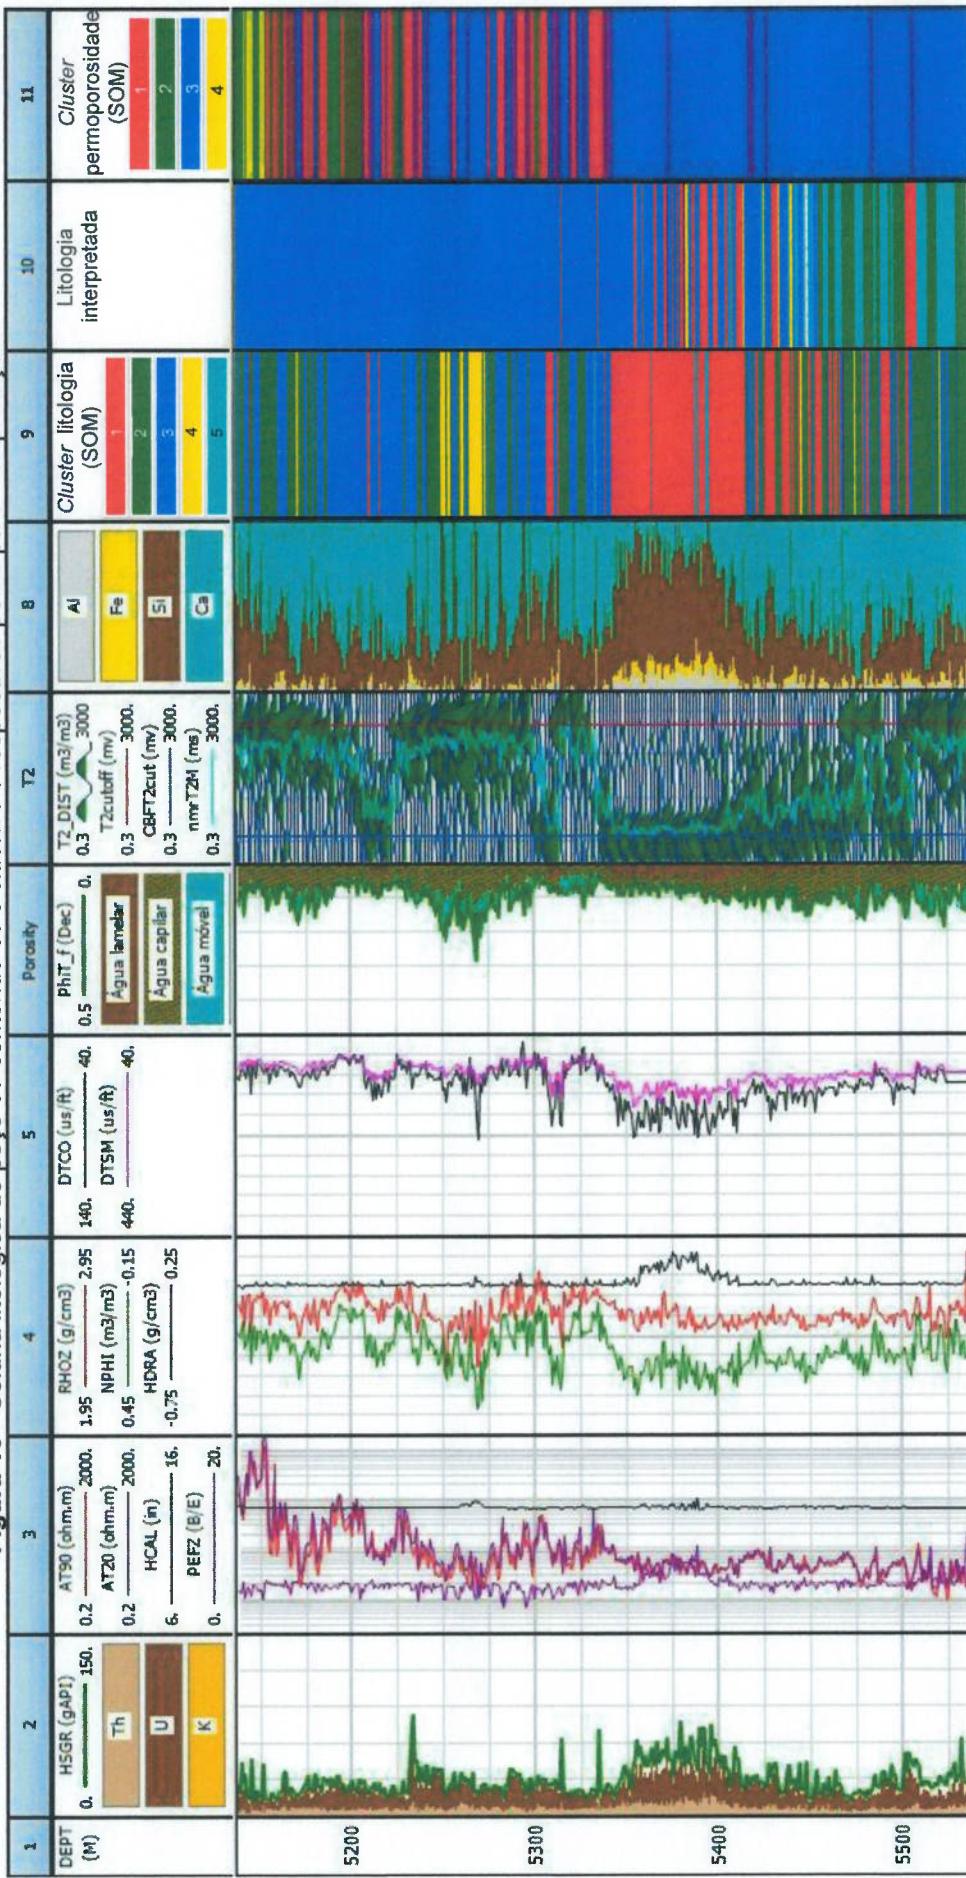


Figura 16 - Coluna litológica do poço 97 contendo os 5 clusters e respectivos perfis para interpretação.



Outra característica a ser pontuada é a diferença de distribuição das litologias do poço 6 frente aos demais poços. Este fator está provavelmente associado à posição dos poços no campo, visto que o poço 6 foi perfurado na porção norte do campo enquanto os demais poços se encontram na porção mais ao sul (Figura 6).

### 6.3.2 Comparação com amostras laterais

Uma segunda forma de validação dos resultados foi adotada visando qualificar a capacidade de classificação de rochas carbonáticas. Para tal, os dados obtidos foram comparados com amostras laterais (Tabela 7). Os tipos litológicos presentes nos trechos dos poços analisados foram divididos em oito grupos principais: 1- laminito e carbonatos finos, 2- retrabalhados, 3- estromatólitos e outras bioconstruções, 4- esferulitos, 5- fácies de alteração (silicificação e dolomitização), 6- calcários cristalinos, 7- siliciclásticos grossos e 8- siliciclásticos finos.

**Tabela 7 - Porcentagem de correspondência entre clusters e amostras laterais.**

clusters	Amostras laterais							
	1	2	3	4	5	6	7	8
1	0%	59%	26%	7%	1%	0%	4%	3%
2	9%	59%	18%	6%	3%	1%	4%	0%
3	12%	49%	17%	11%	6%	1%	1%	2%
4	6%	46%	34%	5%	6%	3%	1%	0%
5	59%	17%	3%	10%	10%	0%	0%	0%

As dificuldades encontradas nesse processo de comparação são devido aos dados de amostras laterais serem muito pontuais em comparação à quantidade de dados obtidos por meio da perfilagem. Além disso, a escala de detalhamento destes diferentes métodos de interpretação litológica também prejudica a comparação.

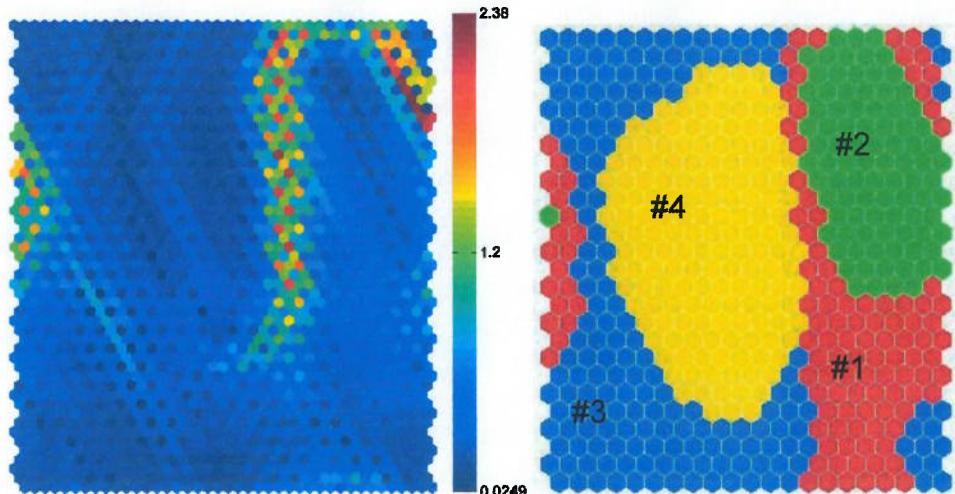
Mesmo com tais dificuldades de comparação pode-se notar a predominância de laminitos e carbonatos finos (tipo litológico 1) no cluster 5, confirmando a afirmação deste cluster se tratar de lamitos. Nos demais clusters existe uma predominância de rochas retrabalhadas, que consistem em rochas carbonáticas com diferentes porcentagens de argila. Sendo assim esta classificação é pertinente no caso do cluster 1, o qual foi definido como argilas magnesianas.

Os clusters 2, 3 e 4 não são possíveis de serem diferenciados por comparação com amostras laterais e as litologias como os calcários cristalinos e as rochas siliciclásticas grossas e finas possuem uma amostragem muito pequena e por esse motivo não foram separados em clusters específicos.

## 6.4 SEPARAÇÃO DE FLUIDOS E IDENTIFICAÇÃO DE ZONAS PERMOPOROSAS

Para análise das zonas com maiores permoporosidade foi realizado um novo processamento utilizando somente os perfis de resistividade e neutrônico. Neste novo caso obteve-se uma divisão em 4 *clusters* como ilustrado na Figura 17.

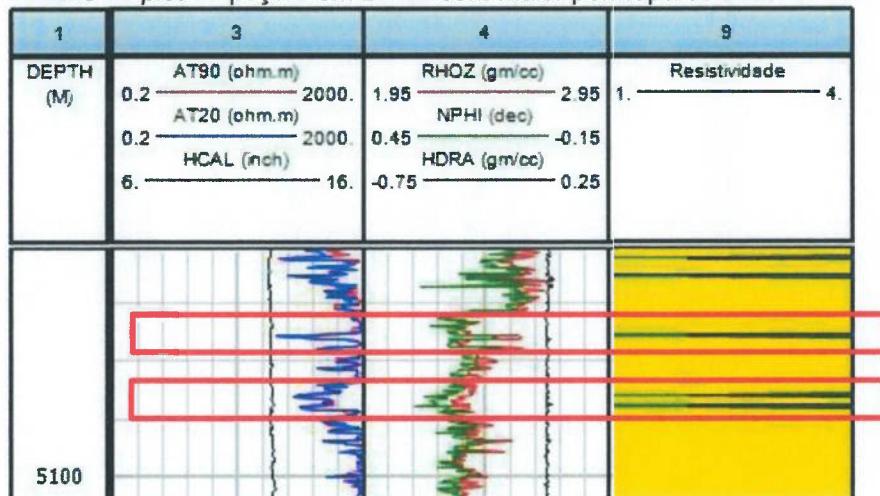
Figura 17 - Matriz U obtida por mapa 26x21 (à esquerda) e *clusters* obtidos (à direita).



Os resultados da classificação de cada poço obtidos nesta análise foram plotados com auxílio do software IP® e podem ser visualizado na coluna 11 das figuras Figura 13, Figura 14, Figura 15 e Figura 16.

Pode-se notar, especialmente nos poços 6, 55 e 82 uma clara separação entre zona de óleo (em amarelo) e zona de água (em azul). Nas zonas de óleo nota-se, a existência de faixas de coloração verde, indicando áreas com maior permoporosidade. Na Figura 18 é possível visualizar o aumento dos valores de NPHI e diminuição das resistividades nas áreas demarcadas.

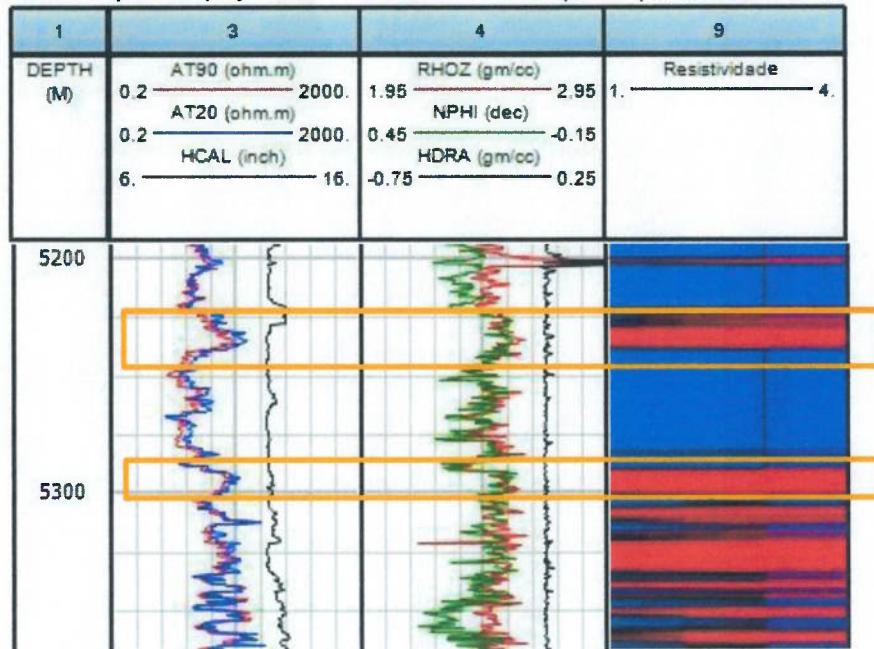
Figura 18 – Detalhe do plot do poço 6 em zonas com maior permoporosidade em zonas de óleo.



Da mesma forma, nas zonas de água verificam-se faixas, agora vermelhas, ou seja, diferentes das existentes em zonas de óleo, onde há maior permoporosidade

Figura 19.

Figura 19 - Detalhe do *plot* do poço 6 em trechos com maior permoporosidade em zonas de água .



A definição destes trechos é de fundamental importância não somente na zona de óleo, para definição das melhores profundidades para produção, mas também na zona de água, indicando os melhores pontos para injeção de fluidos como método de recuperação.

## 7 CONCLUSÕES

As análises realizadas neste projeto, permitiram constatar o potencial da técnica “*Self-Organizing Maps*” como ferramenta complementar à análise litológica com base em perfis de poços em ambientes carbonáticos, visto que a sistemática de classificação empregada gerou resultados semelhantes aos obtidos pela técnica usual de interpretação visual.

Baseado nas análises estatísticas desenvolvidas determinou-se os perfis mais adequados para a classificação litológica proposta, sendo possível identificar padrões de reconhecimento e gerando uma classificação dos dados em cinco tipos litológicos distintos, valor pertinente dentro dos dados analisados.

Ressalta-se, porém, que a técnica gerou interpretações mais detalhadas do que a interpretação visual, gerando certas divergências de resultados. A interpretação visual classifica de maneira uniforme e simplificada grandes trechos do poço, enquanto através do SOM é possível identificar maiores intercalações litológicas.

Em relação a determinação de regiões com características distintas de permoporosidade, definiu-se após diversos testes que os perfis de resistividade assim como o neutrônico são os mais indicados. Através da análise com base nos perfis mencionados há a identificação do contato óleo/água e de zonas demarcadas com maior permoporosidade, o que é de fundamental importância para a produção e injeção de fluidos.

## REFERÊNCIAS

- ARCHIE, G. E. The Electrical Resistivity Log as an Aid in Determining Some Reservoir Characteristics. *Transactions of the AIME*, v. 146, n. 01, p. 54–62, 1941.
- ASFAHANI, J.; AHMAD, Z.; GHANI, B. A. Self organizing map neural networks approach for lithologic interpretation of nuclear and electrical well logs in basaltic environment, Southern Syria. *Applied Radiation and Isotopes*, v. 137, n. March, p. 50–55, 2018.
- BALDISSERA, P. R.; REMACRE, A. Z.; TIBANA, P. **Modelagem estocástica de fácies para caracterização da distribuição espacial das heterogeneidades de reservatório.** [s.l.] Universidade Estadual de Campinas, 1992.
- BHATT, A.; HELLE, H. B. Determination of facies from well logs using modular neural networks. *Petroleum Geoscience*, v. 8, n. 3, p. 217–228, 2002.
- Boletim da Produção de Petróleo e Gás Natural. Disponível em: <<http://www.petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/pre-sal/>>.
- BRANCO, F. D. R. **ESTIMATIVAS DA PERMEABILIDADE ATRAVÉS DA ANÁLISE DE NOVAS TECNOLOGIAS: O PERFIL NMR.** Universidade Estadual do Norte Fluminense, 2012.
- BURCHETTE, T. P. Carbonate rocks and petroleum reservoirs: a geological perspective from the industry. *Geological Society, London, Special Publications*, v. 370, n. 1, p. 17–37, 2012.
- CARNEIRO, C. D. C. et al. Semiautomated geologic mapping using self-organizing maps and airborne geophysics in the Brazilian Amazon. *Geophysics*, v. 77, n. 4, p. K17–K24, 2012.
- CHAUHAN, V.; MOURIK, M. VAN; FLORENCIO, P. Challenges across Brazil's oil sector and prospects for future production. *WPM Archives*, v. WPM 55, n. October, p. 29, 2014.
- DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. PAMI-1, n. 2, p. 224–227, 1979.
- DOLL, H. G. Introduction to Induction Logging and Application to Logging of Wells Drilled With Oil Base Mud. *Journal of Petroleum Technology*, v. 1, n. 6, p. 148–162, 1949.
- ELLIS, D. V.; SINGER, J. M. **Well Logging for Earth Scientists.** Second ed.

- Dordrecht, The Netherlands: Springer, 2008.
- ERNESTO, M.; USSAMI, N. **Introdução à geofísica**. São Paulo, 2002.
- FRASER, S. J.; DICKSON, B. L. A new method for data integration and integrated data interpretation: self-organizing maps. **Proceedings of Exploration 07: Fifth Decennial International Conference on Mineral Exploration**, v. 7, p. 907–910, 2007.
- HAYKIN, S. Redes neurais: princípios e prática. Bookman, p. 900, 2001.
- KOHONEN, T. **Self-Organizing Maps**. Segunda ed. Springer Series, Information Sciences, 1997.
- KOHONEN, T. **Self-Organizing Maps**. Terceira ed. Springer, Berlin, Heidelberg, 2001.
- KOHONEN, T. Essentials of the self-organizing map. **Neural Networks**, v. 37, p. 52–65, 2013.
- KURODA, M. C. **Técnicas de Aprendizagem de Máquina Bio-Inspiradas Aplicadas ao Estudo de Rochas Reservatório**, 2015.
- MELLO, S. F. DE. **Caracterização de Fluido e Simulação Composicional de Injeção Alternada de Água e CO<sub>2</sub> para Reservatórios Carbonáticos Molháveis à Água**. [s.l.] Universidade Estadual de Campinas, 2015.
- NETO, A. A. Uso da sísmica de reflexão de alta resolução e da sonografia na exploração mineral submarina. **Revista Brasileira de Geofísica**, v. 18, n. 3, p. 241–256, 2001.
- Plano de Desenvolvimento Sapinhoá**. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. 2017.
- POULTON, M. M. **Computational Neural Networks for Geophysical Data Processing**. Primeira ed. Pergamon, 2001.
- RIBEIRO, F. S. DE A.; LANDAU, L.; SOARES, J. A. **Aplicação de Análise Multivariada na Predição de Perfis Faltantes de Poços no Campo de Namorado**. [s.l.] Universidade Federal do Rio de Janeiro, 2008.
- SCHLUMBERGER. Wireline Services Catalog. p. 81, 2015.
- SERRA, O. **Fundamentals of Well-Log Interpretation**. first ed. Amsterdam, The Netherlands: Elsevier Science Publishers, 1984.
- SERRA, O. **The Well Logging Handbook**. Paris: Technip, 2008.
- SPADA, N. S. **Classificação litológica por meio de análise multivariada aplicada**

**a perfis de poços de petróleo perfurados na Bacia de Santos.** Universidade de São Paulo, 2016.

**THOMAS, J. E. Fundamentos de Engenharia de Petróleo.** Rio de Janeiro: Interciênci, 2001.

**VESANTO, J. et al. Self-Organizing Map in Matlab: the SOM Toolbox.** Matlab-DSP.Finlandia, 2000.

**WILLIAMS, D. M. The Acoustic Log Hydrocarbon Indicator**SPWLA 31st Annual Logging SymposiumLafayette, LouisianaSociety of Petrophysicists and Well-Log Analysts, 1990.



## Classificação litológica e identificação de zonas permoporosas em perfis de poços com base em redes neurais artificiais não supervisionadas

Nathália Seiler Spada.

Orientador: Prof. Dr. Cleyton de Carvalho Carneiro.

Co-Orientador: Lucas Blanes de Oliveira.

Artigo Sumário referente à disciplina PMI1096 – Trabalho de Formatura para Engenharia de Petróleo II

Este artigo foi preparado como requisito para completar o curso de Engenharia de Petróleo na Escola Politécnica da USP.

Template versão 2018v11.

### Resumo

A técnica de perfilagem de poços de petróleo consiste em um relevante mecanismo para a compreensão estratigráfica de bacias sedimentares bem como para o detalhamento de reservatórios de hidrocarbonetos. Tradicionalmente, as interpretações destes perfis são elaboradas por interpretação visual, tendo como base as diferentes respostas de registros físico-químicos apresentados nos perfis geofísicos dos poços, ou através de redes neurais artificiais supervisionadas. Estes formatos de interpretação apresentam limitações, especialmente em áreas pouco exploradas, onde o conhecimento prévio é reduzido. O presente trabalho utiliza a técnica *Self-Organizing Maps* (SOM), uma rede neural artificial não supervisionada, no intuito de identificar e individualizar padrões de similaridade em perfis geofísicos de múltiplos poços, para que estes possam ser traduzidos em classes litológicas. Foram analisados, em conjunto, dados de quatro diferentes poços da Bacia de Santos, no Pré-sal brasileiro. Através da metodologia empregada verificou-se uma boa correlação entre os resultados obtidos pelo SOM e pela técnica usual de interpretação visual, sendo identificado cinco diferentes grupos litológicos (carbonatos, lamitos e argilas magnesianas). Em uma segunda etapa, foram identificados os perfis que melhor se adequam a identificação de zonas com diferentes permoporosidades. Como resultado, obteve-se clara separação entre zona de óleo e zona de água, além da determinação de trechos mais permoporosos em ambas as zonas.

**Palavras-Chave:** Perfilagem de poços. Mapas auto-organizáveis. Redes neurais artificiais.

### Abstract

The technique of well logging consists of a relevant mechanism for the stratigraphic understanding of sedimentary basins as well as for the detailing of hydrocarbon reservoirs. Traditionally, the interpretations of these logs are elaborated by visual interpretation, based on the different responses of physical-chemical records presented in the geophysical well logs, or through supervised artificial neural networks. These interpretation present limitations, especially in poorly explored areas where prior knowledge is reduced. This work uses the Self-Organizing Maps (SOM) technique, an unsupervised artificial neural network, in order to identify and individualize patterns of similarity in geophysical logs of multiple wells, so that they can be translated into lithologic classes. Data from four different wells of the Santos Basin in the Brazilian Pre-salt were analysed. A good correlation was found between the results obtained by SOM and the usual visual interpretation technique. Five different lithological groups were identified. In a second stage, the profiles that best fit the identification of zones with different permoporosities were identified. As a result, a clear separation between oil zone and water zone was obtained, in addition to the determination of more permoporous stretches in both zones.

**Keywords:** Well logging. Self-Organizing Maps. Artificial neural network.

## 1. Introdução

A descoberta de grandes reservatórios de óleo leve no Pré-Sal das Bacias de Campos e Santos atraíram a atenção da indústria do petróleo no país. A descoberta destes novos campos foi classificada como uma das maiores e mais significativas descobertas de petróleo das últimas décadas e, atualmente, a produção do Pré-sal corresponde a cerca de 54% do total produzido no Brasil (Boletim da Produção de Petróleo e Gás Natural, 2018; CHAUHAN; MOURIK; FLORENCIO, 2014).

Estes promissores reservatórios selados pela espessa sedimentação evaporítica são compostos, predominantemente, por variedades de carbonatos. Tal família de rochas apresenta uma natureza complexa e heterogênea de porosidade, permeabilidade e continuidade vertical das camadas (BURCHETTE, 2012), fatores que aumentam a complexidade da caracterização petrofísica e, consequentemente, da sua produção implicando em elevado investimento e alto custo de produção (MELLO, 2015).

Para o melhor entendimento geológico do campo e análise das incertezas associadas à exploração e produção de óleo e gás faz-se uso da caracterização de reservatórios. A caracterização, portanto, combina conhecimentos de diversos áreas para a construção de modelos integrados, onde são reunidas as informações e dados disponíveis sobre o reservatório para se prever, monitorar e otimizar a performance do mesmo durante todo o seu ciclo de vida.

Dentre os mais importantes métodos de exploração e caracterização de reservatórios encontram-se os perfis geofísicos de poços, onde parâmetros relacionados à porosidade, litologia, presença de hidrocarbonetos e outras propriedades das rochas podem ser obtidos (SERRA, 1984). De posse de tais interpretações torna-se possível a elaboração de modelos estratigráficos das bacias sedimentares bem como o detalhamento de reservatórios de hidrocarbonetos.

Tradicionalmente, as interpretações destes perfis são elaboradas por interpretação visual, tendo como base as diferentes respostas de registros físico-químicos. Além desse formato, tais interpretações por vezes se baseiam em redes neurais artificiais, sobretudo aquelas supervisionadas, onde há a necessidade de inserção de parâmetros de treinamento definidos por um especialista. Estes formatos de interpretação apresentam limitações, especialmente em áreas pouco exploradas, onde o conhecimento *a priori* é reduzido.

Com o propósito de alcançar um melhor entendimento das diversidades presentes nos campos carbonáticos propõe-se o desenvolvimento de novas estratégias computacionais que auxiliem a interpretação de dados de caracterização de reservatórios e a tomadas de decisões, diminuindo riscos e incertezas associados.

Diversos métodos de modelagem espacial de dados possibilitam o aperfeiçoamento do processo de interpretação a partir da atribuição de parâmetros sistemáticos e semiautomáticos. São exemplos de técnicas de modelagem espacial de dados as guiadas pelo conhecimento (*knowledge-driven*), ou aquelas guiadas pelos dados (*data-driven*). O método *Self-Organizing Maps* – SOM (KOHONEN, 1997) ou Mapas Auto Organizáveis é uma abordagem *data-driven* e foi selecionado para este trabalho visto que possibilita a melhor visualização das relações topológicas e topográficas dos dados e suas propriedades.

A técnica SOM foi aplicada visando a tradução dos perfis de diversos poços em classes litológicas, observando constituição, geometria e abrangência das classes geradas. Em uma segunda etapa, perfis serão selecionados e utilizados como base para identificação automática de zonas com maior permoporosidade.

## 2. Metodologia

Neste projeto foram utilizados dados de perfis de quatro poços da bacia de Santos do acervo do Banco de Dados de Exploração e Produção (BDEP) criado pela Agência Nacional de Petróleo (ANP).

Visando a classificação das amostras utilizou-se a rotina proposta por Carneiro et al. (2012) para dados geológicos. No entanto, neste trabalho, foi necessária uma adaptação para as variáveis

relacionadas à reservatórios de petróleo.

O primeiro parâmetro a se definir é o espaço n-dimensional onde se encontram as amostras. Esse número determina o tamanho do mapa de saída e, consequentemente, o número de vetores semente que serão treinados para representar a distribuição original de amostras no espaço de dados. De acordo com Vesanto et al. (2000), o tamanho do mapa pode ser calculado a partir da Equação 1:

$$\text{Tamanho do mapa} = 5 \times \sqrt{\text{número de linhas de amostra}} \quad (1)$$

Para as análises foi utilizado o software SiroSOM®. Uma grade hexagonal foi escolhida como formato de visualização e a superfície de um hipervolume toroidal utilizada para a projeção dos neurônios ou *best-matching units* (BMU), de forma que seja possível a melhor visualização espacial da semelhança entre os dados e para que a topografia seja preservada.

Os dados foram analisados e preparados utilizando-se a plataforma IP® e posteriormente formatados para a leitura vetorial das amostras. Cada amostra representa uma profundidade de medição e apresenta um valor para cada uma das variáveis inseridas nas análises, neste caso, os perfis de poços.

Em um primeiro momento, todas as variáveis foram inseridas no ambiente SOM visando verificar a interdependência entre os perfis por meio da análise do coeficiente de determinação. Com base nesses resultados os perfis que apresentaram índice de correlação menor que 0,01 e maior que 0,99 foram suprimidos por interferir de forma negativa na clusterização. A tabela com os dados selecionados foi, então, novamente introduzida na plataforma SOM.

Após o ajuste dos vetores, todas as amostras originais foram representadas em um mapa 2D onde a topografia entre as amostras é preservada (matriz U). Obteve-se também como saída do processamento as parcelas componentes de cada perfil e os BMU de cada curva. Cada neurônio ou BMU no mapa auto organizável representa um “mini-cluster” das variáveis de entrada. No entanto, para entender o comportamento destes neurônios em grupamentos maiores, é necessário realizar uma segunda classificação, desta vez, entre os hexágonos resultantes do mapa-auto organizável.

A classificação dos neurônios resultantes se deu a partir da média-K, baseando-se no número de classes determinadas pelas análises de Davies e Bouldin (1979). Como resultados, obteve-se a clusterização dos dados a partir do mapa de similaridade entre as amostras permitindo a separação de amostras conforme suas características de similaridade natural.

Uma segunda análise foi realizada visando a classificação de zonas com maior permoporosidade. Para isso foram utilizados apenas os perfis de resistividade e porosidade. O processamento foi executado de maneira similar ao processamento da primeira análise.

Após a classificação dos tipos litológicos por meio da metodologia descrita os resultados foram comparados com a descrição realizada de maneira tradicional por geólogos. Neste procedimento são comparados o número de litologias diferentes presentes nos trechos analisados, os tipos litológicos e a distribuição dos mesmos ao longo dos poços. Comparou-se ainda se a técnica conseguiria identificar as diferentes formações presentes, Barra Velha e Itapema.

### 3. Resultados

#### 3.1. Preparação dos dados para a separação litológica

Para definir os melhores perfis para a clusterização observou-se a correlação entre as variáveis. Quanto maior a correlação entre perfis, mais redundante se torna a informação, o que é prejudicial à análise. Visto que este é o caso dos perfis de resistividade (AT10, AT20, AT30, AT60 e AT90) estes foram suprimidos. Os dados relativos a quantidade de gadolínio, enxofre e titânio foram também retirados da análise devido à baixa quantidade destes componentes frente aos demais.

#### 3.2. Definição das diferentes litologias

A matriz U obtida é representada na Figura 1 de modo que a escala de cores indica as semelhanças entre nós adjacentes no mapa da seguinte maneira: as cores frias (azul) indicam grande similaridade

entre os nós adjacentes e as cores quentes (vermelho) menor similaridade. A partir destas zonas de similaridade e dissimilaridade as amostras foram agrupadas em grupos ou clusters. Como resultado da primeira análise obteve-se um número ótimo de cinco *clusters*, ou seja, cinco classes litológicas.



Figura 1 – Matriz U obtida por mapa 26x21 (à esquerda) e *clusters* obtidos (à direita).

Cada variável influí para a geração desta matriz U já que, para cada par de amostras, tem-se variáveis semelhantes ou distintas. Para analisar a influência de cada perfil nos cinco *clusters* definiu-se faixas de valores (alta, média ou baixa) e estes foram comparados entre si. Pode-se verificar que o *cluster* 4 é o grupo que apresenta litologias de menor densidade e alta porosidade. Já os *clusters* 1 e 5 são diferenciados dos demais devido a uma maior quantidade de tório, sendo esta ainda mais elevada no *cluster* 5. Este último apresenta também elevado teor de potássio levando a associação deste tipo litológico com lamitos presentes no Pré-sal. As características do *cluster* 1 se assemelham a argilas magnesianas. Os *clusters* 2 e 3 apresentam característica bem semelhantes entre si tornando mais difícil a identificação litológica.

### 3.3. Validação dos resultados litológicos

Ao se comparar o resultado do SOM com a interpretação visual realizada por geólogos nota-se uma predominância dos *clusters* 3 e 4. Essas litologias são descritas como carbonatos na interpretação visual contudo há uma diferenciação destas no resultado da técnica SOM. Os trechos referentes ao *cluster* 2, que aparecem de forma mais recorrente no fundo dos poços, estão relacionados a marga e apresentam alta correspondência em ambas as interpretações.

Em especial no poço 82 verifica-se que o *cluster* 1 está associado as litologias descritas como argilas magnesianas enquanto o *cluster* 5, lamitos. Estas litologias foram facilmente identificadas pelo SOM e correspondem ao resultado de interpretação visual por geólogos.

Em seguida, notou-se que os lamitos presentes na parte inferior dos poços 6 e 82 podem indicar o topo da formação Itapema e base da formação Barra Velha, que são as formações atravessadas pelos trechos de poços trabalhados. As profundidades em que essas rochas são indicadas nos perfis conferem com a análise geológica.

Outra característica a ser pontuada é a diferença de distribuição das litologias do poço 6 frente aos demais poços. Este fator está provavelmente associado a posição dos poços no campo, visto que o poço 6 foi perfurado na porção norte do campo enquanto os demais poços se encontram na porção mais ao sul

### 3.4. Separação de fluidos e identificação de zonas permoporosas

Para análise das zonas mais permoporosas foi realizado um novo processamento utilizando somente os perfis de resistividade e porosidade. Neste novo caso obteve-se uma divisão em 4 *clusters*.

A partir dos resultados de classificação de cada poço em zonas de diferentes permoporosidades nota-se, especialmente nos poços 6, 55 e 82 uma clara separação entre zona de óleo e zona de água. Distinguem-se também faixas verdes e vermelhas onde a permoporosidade é reduzida. Estas informações são comprovadas ao se analizar os valores de porosidade no perfil NPHI e resistividade.

Todos os resultados apresentados podem ser visualizados nas figuras 2 e 3, assim como a comparação com a litologia interpretada de maneira visual.

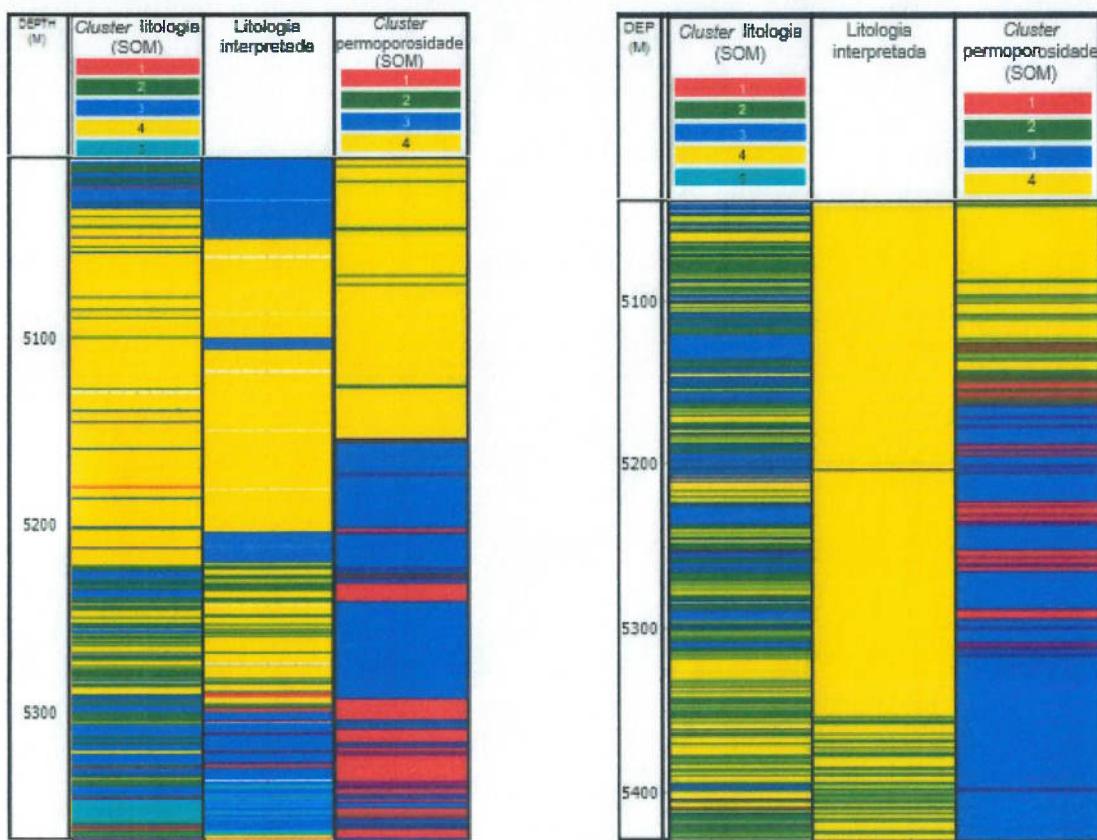


Figura 2 – Resultados obtidos para o poço 6 (esquerda) e no poço 55 (direita).

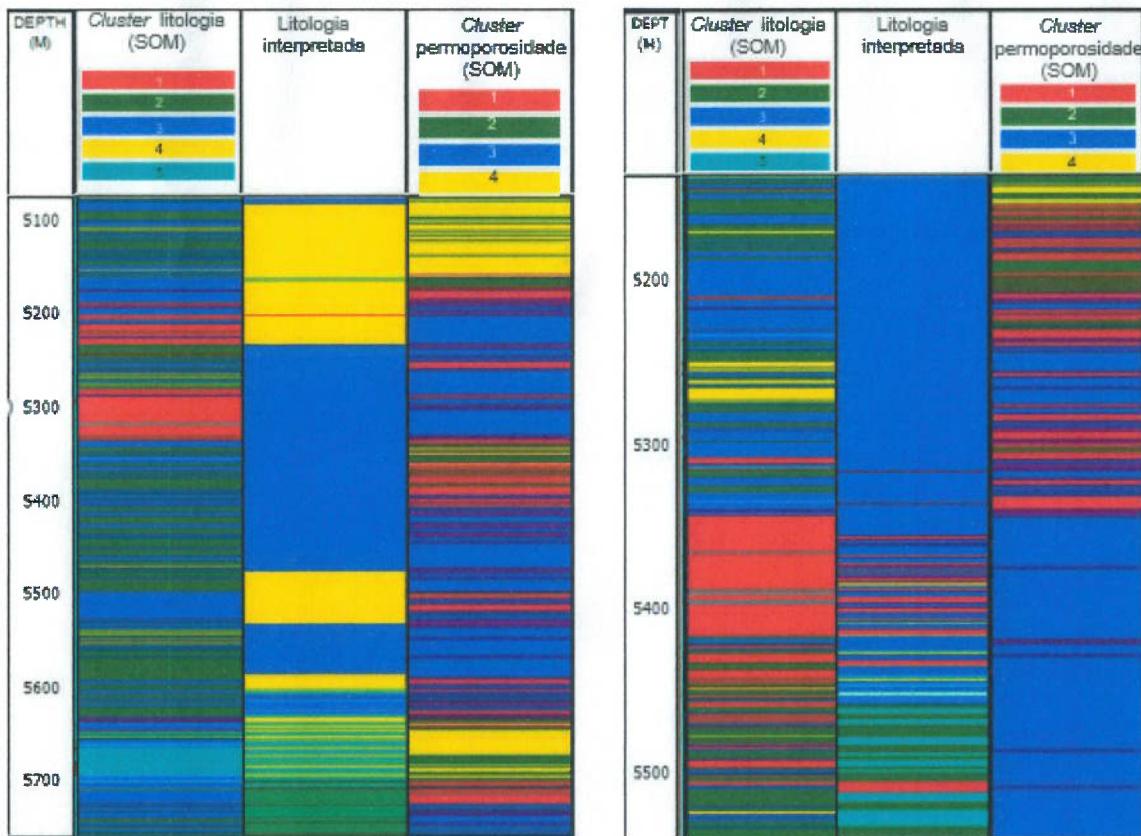


Figura 3 - Resultados obtidos para o poço 82 (esquerda) e no poço 97 (direita).

#### 4. Conclusão

As análises realizadas neste projeto, permitiram constatar o potencial da técnica “*Self-Organizing Maps*” como ferramenta complementar à análise litológica com base em perfis de poços em ambientes carbonáticos, visto que a sistemática de classificação empregada gerou resultados semelhantes aos obtidos pela técnica usual de interpretação visual.

Baseado nas análises estatísticas desenvolvidas determinou-se os perfis mais adequados para a classificação litológica proposta, sendo possível identificar padrões de reconhecimento e gerando uma classificação dos dados em cinco tipos litológicos distintos, valor pertinente dentro dos dados analisados.

Ressalta-se, porém, que a técnica gerou interpretações mais detalhadas do que a interpretação visual, gerando certas divergências de resultados. A interpretação visual classifica de maneira uniforme e simplificada grandes trechos do poço, enquanto através do SOM é possível identificar maiores intercalações litológicas.

Em relação a determinação de regiões com características distintas de permoporosidade, definiu-se após diversos testes que os perfis de resistividade assim como o neutrônico são os mais indicados. Através da análise com base nos perfis mencionados há a identificação do contato óleo/água e de zonas demarcadas com maior permoporosidade, o que é de fundamental importância para a produção e injeção de fluidos.

#### 5. Referências

- BALDISSERA, P. R.; REMACRE, A. Z.; TIBANA, P. **Modelagem estocástica de fáceis para caracterização da distribuição espacial das heterogeneidades de reservatório.** Universidade Estadual de Campinas, 1992.
- Boletim da Produção de Petróleo e Gás Natural. Disponível em: <<http://www.petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/pre-sal/>>.
- BURCHETTE, T. P. Carbonate rocks and petroleum reservoirs: a geological perspective from the industry. **Geological Society, London, Special Publications**, v. 370, n. 1, p. 17–37, 2012.
- CARNEIRO, C. D. C. et al. Semiautomated geologic mapping using self-organizing maps and airborne geophysics in the Brazilian Amazon. **Geophysics**, v. 77, n. 4, p. K17–K24, 2012.
- CHAUHAN, V.; MOURIK, M. VAN; FLORENCIO, P. Challenges across Brazil's oil sector and prospects for future production. **WPM Archives**, v. WPM 55, n. October, p. 29, 2014.
- DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-1, n. 2, p. 224–227, 1979.
- KOHONEN, T. **Self-Organizing Maps.** Springer Series, Information Sciences, 1997.
- MELLO, S. F. DE. **Caracterização de Fluido e Simulação Composicional de Injeção Alternada de Água e CO<sub>2</sub> para Reservatórios Carbonáticos Molháveis à Água.** [s.l.] Universidade Estadual de Campinas, 2015.
- SERRA, O. **Fundamentals of Well-Log Interpretation.** first ed. Amsterdam, The Netherlands: Elsevier Science Publishers, 1984.
- VESANTO, J. et al. **Self-Organizing Map in Matlab: the SOM Toolbox.** Matlab-DSP. Finlandia: 2000.