



Associação de Estatística Multivariada com Redes Neurais e Lógica Fuzzy para Identificação automática de litologias usando perfis de poço do Campo de Namorado na Bacia de Campos, Brasil.

Roosevelt Tavares Flexa*, UENF/LENEP, A. Abel G. Carrasquilla, UENF/LENEP, Jadir da Conceição da Silva, UFRJ, Brazil

Copyright 2005, SBGf - Sociedade Brasileira de Geofísica

This paper was prepared for presentation at the 9th International Congress of the Brazilian Geophysical Society held in Salvador, Brazil, 11-14 September 2005.

Contents of this paper were reviewed by the Technical Committee of the 9th International Congress of the Brazilian Geophysical Society. Ideas and concepts of the text are authors' responsibility and do not necessarily represent any position of the SBGf, its officers or members. Electronic reproduction or storage of any part of this paper for commercial purposes without the written consent of the Brazilian Geophysical Society is prohibited.

Abstract

In search of the petroleum reservoir characterization, the first task executed is the identification of lithologies crossed by the well, which may be achieved through the analysis of core sampling. However, this method is considered expensive and lengthy. Another way is through the interpretation of well logs, which are calibrated with some data from core samples and then extrapolated to the entire field. Although the interpretation using well logs is considered more economic, in some cases, due to the mineralogical complexity of these rocks, satisfactory results are not attained. This fact is because of the use of conventional statistical or mathematical algorithms.

This paper presents a new methodology that associates multivariate statistical methods with neural networks and fuzzy logic, applied to the automatic identification of lithologies using only well log data. The data were obtained from the Namorado oil field in the Campos Basin, Brazil, given by ANP (Petroleum National Agency). This methodology is considered cheap, and was divided into three stages: first, using well log data that represents various lithological types (gamma rays (GR) and density (RHOB)), we applied a fuzzy logic algorithm to them to determine the quantity of clusters.

Next, we develop a competitive neural network, based on Kohonen's learning rule. The input layer was composed of two neurons (with the same number of logs used) and the competitive layer was composed of neurons, with the same number of clusters determined by the fuzzy logic algorithm.

In the final stage, some databank elements of the lithological types were randomly selected to be used as discriminant variables, which correspond to the input data of the multi-group discriminant analysis program. Finally, the lithological types were identified automatically throughout the well.

Introdução

Para a caracterização de reservatórios de petróleo, deve-se realizar, primeiramente, a identificação das litologias atravessadas pelo poço petrolífero, que pode ser feito através de análises de testemunhos, que são caros e demorados, ou através da interpretação de dados de perfis de poço, que são mais baratos e mais rápidos.

Contudo, a identificação das litologias utilizando dados de perfis de poço em alguns casos torna-se uma tarefa difícil devido à ocorrência de ambigüidades em suas medidas, e também devido a complexidade mineralógica destas rochas. Deve-se lembrar que as medidas ou respostas dos perfis de poço são afetadas pela variação das propriedades físicas das rochas.

O ato de promover a identificação das litologias através de dados de perfis de poço é uma das contribuições mais importantes da geofísica de poço aos estudos geológico dentro da indústria de petróleo. Para esta tarefa, vários trabalhos aplicaram algoritmos computacionais convencionais e métodos estatísticos que obtiveram bons resultados em aplicações geológicas e geofísicas, como os obtidos por Serra & Abbot (1989) e Bucheb (1991), os quais fizeram o uso de vários métodos estatísticos na determinação de litologias e eletrofácies. Porém, em tais aplicações, se fez necessário a participação do intérprete no fornecimento de informações prévias para que se definissem padrões nos dados de perfis de poço.

Alguns trabalhos utilizaram redes neurais para identificação de litofácies (Chang et al., 2001), já outros utilizaram estatística multivariada e redes neurais em problemas de engenharia de reservatório, mas de forma independente e separado (Nitters et al., 1995).

Sendo assim, no intuito de promover a identificação de litologias de uma forma mais eficiente, este trabalho apresenta uma metodologia de baixo custo, que propõe a associação da regra *Fuzzy* com a rede neural competitiva e a técnica de análise discriminante multigrupo, para a identificação automática de litologias em dados de perfis de poço, ressaltando que esta associação vem a ser um fato inédito para esta finalidade.

Metodologia

Inicialmente, trabalhou-se de uma forma simplificada nos procedimentos para identificação automática de litologias fazendo uso apenas de duas medidas de perfis de poço, raios gama (GR) e densidade (RHOB), que são considerados na literatura sensíveis à litologia (Serra & Abbot, 1989). A utilização de apenas dois perfis de poço como vetores de entrada teve o objetivo de ajustar os programas de rede neural e de estatística multivariada para futuras aplicações.

As redes neurais competitivas utilizadas neste trabalho fazem parte das redes neurais com aprendizado não-supervisionado, como o próprio nome sugere, não há um professor ou supervisor para acompanhar o processo de aprendizado. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada (Braga et al., 2000).

A rede neural utilizada neste trabalho é composta fundamentalmente por duas camadas (Andrade et al., 2002), a camada de entrada que possui elementos sensoriais, responsáveis pelos sinais de entrada da rede, e a camada competitiva que caracteriza a rede, é composta por neurônios, que são estimulados a competir entre si, de modo que apenas 01 neurônio permaneça ativo (neurônio vencedor). A arquitetura de uma rede neural com camada competitiva pode ser visualizada na Figura 1.

No desenvolvimento da metodologia deste trabalho, buscou-se, primeiramente, a definição do número de *clusters* que ocorrem nos dados dos perfis de poço, para isto, fez-se o uso de um algoritmo computacional baseado em lógica *fuzzy* (Aguiar & Oliveira, 1999). A definição da quantidade dos *clusters* existentes nos dados será de grande valia para a implementação de rede neural competitiva.

Na etapa seguinte procedeu-se o desenvolvimento de uma rede neural competitiva (Haykin, 1999), composta de dois neurônios (elementos sensoriais) na camada de entrada, isto se deve ao fato da utilização de apenas dados de dois perfis de poço, o perfil de raios gama (GR) e o perfil de densidade (RHOB). Em relação à camada competitiva, a rede neural foi composta por um número de neurônios tal qual a número de *clusters* definidos pelo algoritmo de lógica *Fuzzy*.

Na etapa de treinamento utilizou-se a regra de treinamento de Kohonen (Kohonen, 1989), na qual os pesos sináptico são ajustados pelo processo de treinamento para encontrar os centros dos *clusters* nos vetores de entrada (*input*). O peso sináptico do neurônio ganhador (em uma coluna da matriz de pesos de entrada) é ajustado com a regra de aprendizagem de Kohonen. Supondo que o *i*-ésimo neurônio ganha, o elemento do *i*-ésima coluna da matriz de pesos de entrada é ajustado como mostrado abaixo:

$${}_iW^{l,1}(q) = {}_iW^{l,1}(q-1) + \alpha(p(q) - {}_iW^{l,1}(q-1)), \quad (1)$$

no qual: p é o vetor de entrada, $W^{l,1}(q-1)$ é a matriz de pesos sinápticos inicial, $W^{l,1}(q)$ é a matriz de pesos atualizado e α é a função de ativação.

A regra de Kohonen apresenta uma importante característica, a de que os pesos de um neurônio aprendam com os vetores de entrada, em decorrência deste fato torna-se útil em aplicações de reconhecimento. Após o agrupamento dos *clusters*, fez-se necessário nomear ou rotular tais grupos encontrados, a fim de indicar a qual tipo litológico cada grupo tem maior possibilidade de representar.

A rotulagem dos grupos encontrados foi realizada através da aplicação de um programa computacional baseado na interpretação do *cross-plots* do raio gama (GR) e densidade (RHOB). Neste procedimento levou-se em consideração a concepção clássica da interpretação dos perfis de poço (Ellis, 1987). No final deste processo, os grupos rotulados foram assumidos como tipos litológicos presentes no poço.

Depois do processo de rotulagem, já com a definição dos tipos litológicos presentes no poço, selecionou-se aleatoriamente alguns elementos de cada tipo litológico para compor alguns bancos de dados, que foram

utilizados como dados de entrada (variáveis discriminantes) em um programa de análise discriminante multigrupo.

Neste trabalho aplicaram-se os dados de perfis de poço nas funções discriminantes resultando na identificação automática das litologias em cada ponto de leitura do perfil de poço. As funções discriminantes podem ser matematicamente definidas da seguinte forma:

$$R = I_1y_1 + I_2y_2 + \dots + I_my_m, \quad (2)$$

com $1 \leq k \leq m$, onde m é o número de variáveis utilizado na análise, R é o índice discriminante da função, I_k são os coeficientes da função discriminante e y_k são os valores da k -ésima variável de um determinado objeto. Neste trabalho, os y_k representam dados de perfis de poço.

Desta maneira, efetua-se a associação da lógica *Fuzzy* com as redes neurais competitiva e com a técnica de análise discriminante, conjugando as características distintas dos três métodos, a fim de promover a identificação dos tipos litológicos utilizando-se unicamente perfis de poço, e tentando minimizar a participação do interprete no fornecimento de informações prévias (padrões nos dados de perfis) empregados no processo discriminatório.

Deve-se levar em consideração que a identificação da litologia apenas através de dois perfis GR (raios gama) e RHOB (densidade), não é o ideal, pois como se sabe uma interpretação mais precisa necessitaria de uma interpretação conjunta com mais perfis, como: PHIN (porosidade neutrônica), ILD (resistividade) e DT (tempo de trânsito). A utilização de mais perfis nesta metodologia será realizada em trabalhos futuros.

Resultados

Os primeiros resultados deste trabalho são provenientes da aplicação desta metodologia em dados de perfis de poço (Poço NA02 e Poço NA04).

Na primeira etapa deste trabalho, procedeu-se a construção de uma rede neural competitiva com dois neurônios na camada de entrada *input*, na qual foram utilizados dados de perfis de raios gama (GR) e densidade (RHOB) do Poço NA02, correspondendo a um trecho de 225 m. A camada competitiva da rede neural foi composta de seis neurônios, em decorrência da quantidade de *clusters* definidos pelo algoritmo de lógica *fuzzy* (Figura 2).

Na etapa de treinamento foram utilizadas 200 interações (épocas) para que os pesos sinápticos fossem ajustados, localizando os centros dos *clusters* nos dados de entrada (Figura 3).

Após esta etapa tornou-se necessário nomear ou rotular os grupos encontrados, a fim de indicar a qual tipo litológico, cada grupo tem maior possibilidade de representar. Para isto, aplicou-se um programa computacional que leva em consideração a concepção clássica da interpretação dos perfis de poço. No final deste processo, os grupos rotulados foram assumidos como os tipos litológicos presentes no poço: arenito, carbonato e folhelho, que são os tipos litológicos (Figura 4) esperados para o Campo de Namorado. Para outros campos petrolíferos com litologia mais complexa, deve-se

levar em consideração a ocorrência de outros tipos litológicos.

Na última etapa da metodologia deste trabalho, a partir dos dados dos tipos litológicos presentes no poço, selecionou-se alguns elementos aleatoriamente em torno dos valores médios dos grupos (tipos litológicos) para compor alguns bancos de dados, empregados como dados de entrada (variáveis discriminantes) em um programa de análise discriminante, que realiza a discriminação de vários grupos.

A execução do programa de análise discriminante multigrupo resultou na identificação automática de litologias em cada ponto em profundidade do poço (Figura 5B), que pode ser comparada com os perfis de raios gama e densidade (Figura 5A). O detalhe de um trecho dos resultados pode ser visto na Figura 5C, que pode ser comparado com os resultados de trabalhos anteriores (Flexa et al., 2004) mostrado na Figura 5D, onde foi empregada apenas a técnica de análise discriminante com o auxílio de intérprete no fornecimento dos padrões.

Os resultados deste trabalho também são validados mediante dados de análise de testemunhos do Poço NA02 (Figura 5E) fornecido pela PETROBRAS, demonstrando excelente concordância.

A mesma metodologia utilizada para o poço NA02 foi aplicada em outro poço do Campo de Namorado (Poço NA04). Os resultados obtidos para o Poço NA04 são mostrados na Figura 6B, que pode ser comparado com os perfis de raios gama e densidade (Figura 6A). O detalhe de um trecho dos resultados pode ser visto na Figura 6C, que pode ser comparado com os resultados de trabalhos anteriores (Flexa et al., 2004) mostrado na Figura 6D.

Os resultados também são validados mediante dados de análise de testemunhos do Poço NA04 fornecido pela PETROBRAS (Figura 6E), também demonstrando excelente concordância.

Tomando-se como base os dados de análise de testemunho do Poço NA02, o percentual de concordância para a associação de redes neurais competitivas com análise discriminante multigrupo, foi da ordem de 82,43%, enquanto que no trabalho anterior, onde se aplicou apenas análise discriminante, o desempenho de acertos foi da ordem de 71,62%, como pode ser visto na Tabela 1.

Para o Poço NA04, tomando-se também como referência os dados de análise de testemunho, o percentual de concordância para a associação de redes neurais competitivas com análise discriminante multigrupo, foi da ordem de 71,53%, enquanto que no trabalho anterior, onde se aplicou apenas análise discriminante, o desempenho de acertos foi da ordem de 87,59%, como pode ser visto na Tabela 1.

Tabela 01: desempenho da associação de rede neural competitiva com análise discriminante e trabalho anterior em relação aos dados de testemunho de poço.

Poços	Análise de testemunho (%)	Trabalho anterior (%)	Trabalho atual (%)
NA02	100	71,62	82,43
NA04	100	87,59	71,53

Conclusões

A associação da lógica *Fuzzy* com redes neurais e a técnica de análise discriminante para a identificação de litologias via perfis de poço, apresentou resultados iniciais satisfatórios, apontando para a possibilidade de desenvolvimento de redes neurais competitivas com maior complexidade, composta com um número maior de perfis de poço, o que deverá melhorar o processo de identificação automática de litologias.

Outra possibilidade será estender esta metodologia para identificação automática dos fluidos presentes nos reservatórios como óleo e gás. Na qual se utilizará em conjunto com os perfis sensíveis à litologia, os perfis sensíveis aos fluidos, como: perfil de resistividade (ILD), porosidade neutrônica (PHIN) e densidade (RHOB).

Este trabalho além de promover a associação dos métodos de estatística multivariada (análise discriminante) com rede neural competitiva e regra *fuzzy*, promoveu a incorporação do programa de análise discriminante para o caso multigrupo, o que permitiu que fosse realizada a discriminação entre mais de dois grupos simultaneamente.

Agradecimentos

À UENF e ao CNPq, pela bolsa de doutorado e produtividade em pesquisa destinadas aos autores.

Referências

- Aguiar e Oliveira, H., Jr. 1999. *Lógica Difusa*, Editora Interciência, Rio de Janeiro, 192 p.
- Andrade, A. and Fischetti, A. I., 2002. Porosity images from well logs. *Journal of Petroleum Science and Engineering* 36 (149-158). Elsevier.
- Braga, A.P., Carvalho, A.P.L.F. de & Ludermir, T.B., 2000. *Redes neurais artificiais: teoria e aplicação*. Rio de Janeiro: LTC, 262 p.
- Bucheb, J. A., 1991. *Aplicação de tratamento estatístico multivariante em dados de perfis de poços da Bacia de Sergipe-Alagoas*. Belém, Universidade Federal do Pará, Centro de Geociências. 136p. (Tese de Mestrado).
- Chang, H.C., Kopaska-Merkel, D.C. and Chen, H.C., 2001. Identification of lithofacies using Kohonen self-organizing maps. *Computers and Geosciences* 28 (223-229).
- Ellis, D.V., 1987. *Well logging for Earth Scientists*. Elsevier, USA..
- Flexa, R.T., Carrasquilla, A.A.G. & Andrade, A., 2004. *Identificação da litologia nos perfis de poço do Campo de Namorado (Bacia de Campos, Brasil) e do Lago Maracaibo (Venezuela) aplicando estatística multivariada (A-1449)*, Volume 34, Número 4, *Revista Brasileira de Geociências (RBG)*.
- Haykin, S., 1999. *Neural networks: a comprehensive foundation*. By Prentice-Hall, Inc. Simon & Schuster/A Viacom company Upper Saddle River, New Jersey.
- Kohonen, T., 1989. *Self-organization and associative memory*. Springer-Verlag, Berlin. 312 pp.
- Nitters, G., Davies, D. R. & Epping, W. J. M., 1995. Discriminant analysis and neural nets: Valuable tools to optimize completion practices, *SPE Drilling & Completion*, p. 127-133.

Serra, O. & Abbot, H. T., 1989. The contribution of logging data to sedimentology and stratigraphy, SPE 9270, 18p.

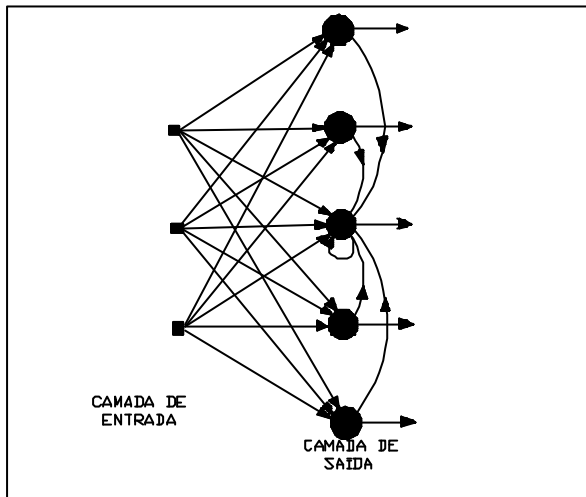


Figura 1 – Modelo de rede neural com arquitetura de camada competitiva.

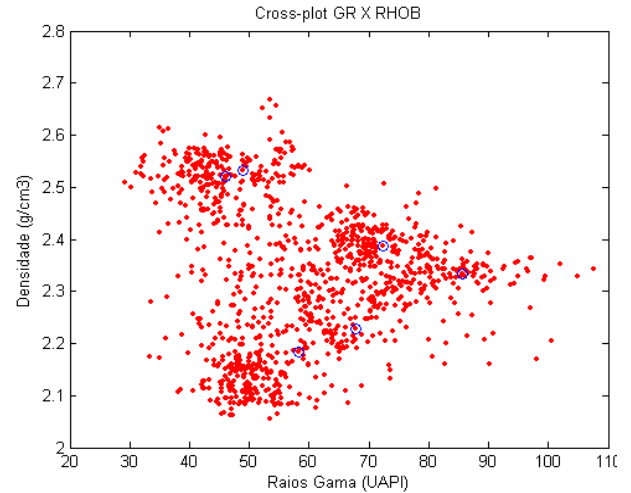


Figura 3 – Dados de perfis do Poço NA02 utilizados como vetores de entrada na rede neural composta de seis neurônios na camada competitiva, com 200 interações (épocas), onde se pode ver a localização dos centros dos clusters.




Figura 2- Exemplo da aplicação do algoritmo de lógica Fuzzy, para determinação do número de cluster para os dados do Poço NA02.

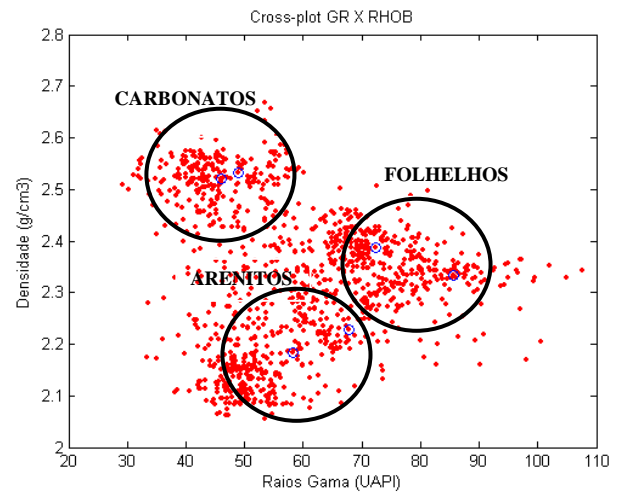


Figura 4 – Resultado da rotulagem dos tipos litológicos presentes no Poço NA02: arenitos, carbonatos e folhelhos.

