

INVESTIGAÇÃO DO TREINAMENTO DE UMA REDE NEURAL PARA O RECONHECIMENTO DE LITOFÁCIES COMBINANDO DADOS DE TESTEMUNHOS E PERFIS DE POÇOS DE PETRÓLEO

Elisângela Silva da Cunha¹, Kyllly Araújo de Oliveira², Herman Martins Gomes²

¹ Faculdade de Tecnologia e Ciências, Rua São Roque, s/n, Feira de Santana/BA,
ecunha.fsa@ftc.br

² Universidade Federal de Campina Grande, Av. Aprígio Veloso, s/n, Campina Grande, PB
kylly@labpetri.dsc.ufpb.br e hmg@dsc.ufcg.edu.br

Resumo – O principal objetivo deste trabalho é investigar o processo de aprendizagem de Redes Neurais aplicadas ao reconhecimento de litofácies (tipos de rocha), quando combinando dados de perfis e testemunhos de poços de um campo de petróleo. A combinação de dados de perfis e testemunhos oferece algumas dificuldades, principalmente devido ao fato de que a localização, nos perfis dos poços, das litofácies obtidas a partir de testemunhos é uma tarefa imprecisa. A identificação de litofácies pode ser obtida por uma análise da amostra do testemunho, porém este é um processo muito caro. Portanto, as amostras de testemunho são retiradas apenas para alguns poços escolhidos estrategicamente. Neste trabalho, foi utilizada uma abordagem baseada em Redes Neurais para adquirir o conhecimento associado ao problema de identificação de litofácies a partir de perfis de poços de petróleo utilizando como saídas desejadas os resultados de classificação encontrados em dados de testemunho. A base de dados foi fornecida pela Agência Nacional do Petróleo (ANP) e contém dados do Campo de Namorado - Rio de Janeiro/Brasil. Este artigo se concentra no processo de aprendizagem e discute algumas estratégias que podem ser úteis na solução do problema investigado.

Palavras-Chave: Identificação de Litofácies de Poços de Petróleo, Redes Neurais Artificiais.

Abstract – The main objective of this work is to investigate the neural network learning process in the lithofacies (types of rocks) identification problem when combining core and well log data from an oil field. The combination of core and well log data has some problems, mainly due to the fact that there is a certain degree of imprecision when locating, within well logs, lithofacies obtained from core data. Lithofacies identification can be accurately done via an analysis of the core data, however this is an expensive process. Thus, core data samples are taken for just a few wells, strategically chosen. In this paper, we used a Neural Network based approach to perform a knowledge acquisition associated to the problem of lithofacies identification from well log data using as target outputs the classification results found in the core data. The database we used was provided by the Brazilian Oil Agency (ANP) and contains data from the Namorado oil field in Rio de Janeiro, Brazil. This paper focuses on the learning process and discusses some strategies that can be used to help solve the problem being investigated.

Keywords: Oil Well Lithofacies Identification, Artificial Neural Networks

1. Introdução

A identificação manual de litofácies de um reservatório de petróleo é um processo intensivo que envolve o gasto de uma quantidade considerável de tempo por parte de um especialista experiente. O problema se torna muito mais difícil conforme aumenta o número de perfis (medidas de determinadas propriedades da formação geológica) simultâneos a serem analisados.

Após a perfuração de uma fase de um poço de petróleo, geralmente são descidas várias ferramentas com a finalidade de medir algumas propriedades das formações, fundamentais para caracterização e avaliação econômica. Este processo é conhecido como perfilagem. A perfilagem permite obter informações importantes a respeito das formações atravessadas pelo poço (Thomas, 2001).

O perfil de um poço é a imagem visual, em relação à profundidade, de uma ou mais características ou propriedades das rochas perfuradas (resistividade elétrica, potencial eletroquímico natural, tempo de trânsito de ondas mecânicas, radioatividade natural ou induzida, etc). Tais perfis, obtidos através do deslocamento contínuo de um sensor de perfilagem (sonda) dentro do poço, são denominados genericamente de perfis elétricos, independentemente do processo físico de medição utilizado (Thomas, 2001).

A identificação de litofácies pode ser feita a partir de dados de perfilagem ou de dados de testemunhagem. A testemunhagem é o processo de obtenção de uma amostra real de rocha de subsuperfície, chamado testemunho, com alterações mínimas nas propriedades naturais da rocha. Com a análise deste testemunho obtêm-se informações valiosas sobre a geologia da formação que serão utilizadas pela engenharia de reservatórios, completação (conjunto de operações destinadas a equipar o poço para produzir óleo ou gás) e perfuração. No entanto, este processo é muito caro e é realizado apenas para alguns poços escolhidos estrategicamente. Já os perfis de poços, estão disponíveis para todos os poços e são menos dispendiosos para se obter.

Os dados de perfis e testemunhos carregam informações diferentes sobre a litologia, por isso a determinação de litofácies a partir destas duas fontes é diferente. Existem várias técnicas para identificação de litofácies a partir de perfis e testemunhos, como por exemplo, análise de agrupamento, métodos de projeção, método *box*, métodos indiretos, segmentação, abordagem preditiva, regras de classificação contextual e outras. As três primeiras técnicas utilizam testemunhos e as demais utilizam perfis (Mohn et al, 1987).

Os métodos que utilizam testemunhos requerem que as alocações de litofácies sugeridas sejam avaliadas por um geólogo. A habilidade destes métodos para formar grupos de profundidade que refletem a litologia do poço depende das variáveis selecionadas. A escolha das variáveis, geralmente, é um resultado de tentativas e erros (Mohn et al, 1987).

Na maioria das técnicas de determinação de litofácies a partir de dados de perfilagem, os perfis são usados para formar grupos de profundidade que devem ser interpretados comparando-os com os dados de testemunho.

O método adotado neste trabalho para identificação de litofácies é baseado em Redes Neurais Artificiais utilizando uma associação de dados de perfis e testemunhos. O principal objetivo deste artigo é discutir as dificuldades da combinação de perfis e testemunhos para identificação de litofácies.

Na Seção 2 será abordado com maiores detalhes o problema de reconhecimento de litofácies. Na Seção 3 serão apresentados os dados selecionados, bem como o pré-processamento realizado nos mesmos. A Seção 4 apresenta os experimentos realizados e os resultados obtidos. Por fim, na Seção 5 serão apresentados as conclusões e os trabalhos futuros.

2. O Problema de Reconhecimento de Litofácies

As informações detalhadas das litofácies de poços testemunhados raramente são extrapoladas e incorporadas quantitativamente durante o estágio de modelagem de um reservatório. Geralmente, nos poços não testemunhados, as modelagens de litofácies são construídas usando as interpretações baseadas em procedimentos de correlação padrão, onde são usados apenas dados limitados de perfilagem de baixa resolução, como por exemplo, raios gama. Isto acontece porque, além da disponibilidade destes perfis, seus comportamentos são bem conhecidos (Coll et al, 1999).

A identificação de litofácies a partir de dados de perfis não permite um nível de detalhamento idêntico ao do testemunho. Isto ocorre porque, nos testemunhos, as litofácies são identificadas e classificadas com base em características medidas em pequena escala e em escalas microscópicas (Coll et al, 1999). No entanto, para este problema, o alto nível de detalhamento dos testemunhos prejudica o processo de aprendizagem da Rede Neural. Outros fatores que prejudicam a aprendizagem (mas que dizem respeito aos perfis) são a pouca quantidade de sensores, ruído presente nos dados e maior imprecisão dos perfis em relação aos testemunhos.

Um dos principais problemas da associação dos dados de perfis e testemunhos diz respeito à localização das litofácies presentes no testemunho na profundidade correta nos perfis. Isto ocorre porque, geralmente, há um pequeno deslocamento da profundidade do testemunho com relação à profundidade do perfil. Embora os dados utilizados já estivessem com o deslocamento devidamente acertado, a confiabilidade não é de 100 %.

O método proposto neste trabalho para o problema de reconhecimento de litofácies compõe-se de duas etapas principais: preparação dos dados - etapa em que os dados de perfis e testemunho são associados e treinamento da Rede Neural - etapa em que a rede aprende a identificar litofácies, conforme ilustra a Figura 1.

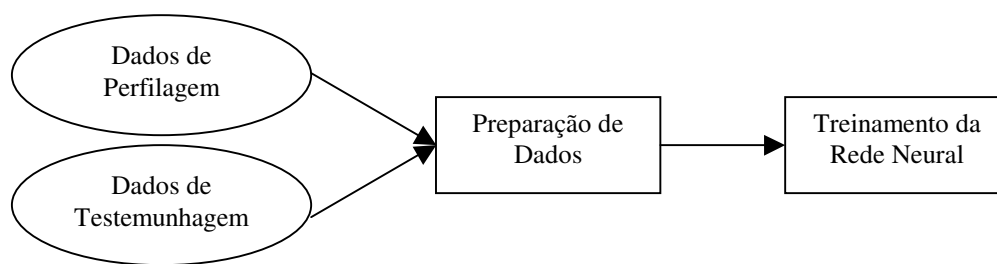


Figura 1 – Arquitetura geral proposta.

3. O Problema de Reconhecimento de Litofácies

A Agência Nacional do Petróleo (ANP) disponibilizou dados para pesquisa do Campo Escola de Namorado - Bacia de Campos, RJ. A seguir, os dados selecionados serão descritos brevemente.

3.1. Dados Selecionados

Com o intuito de resolver o problema de reconhecimento de litofácies, foram selecionados os dados de perfis e descrição dos testemunhos do Campo Escola de Namorado. Nem todos os poços que possuíam dados de perfilagem, possuíam dados de testemunho, mas todos os poços que possuíam dados de testemunho, possuíam dados de perfilagem. Para alguns poços com dados de testemunho, os dados de perfis estavam incompletos, portanto, foram selecionados apenas os poços que, além do testemunho, possuíam todos os perfis. No final restaram apenas 8 poços com descrições dos testemunhos, além dos seguintes perfis: raios gama (GR – permite detectar e avaliar a radioatividade total da formação geológica), sônico (DT – mede a diferença nos tempos de trânsito de uma onda mecânica através das rochas), indução (ILD – fornece leitura aproximada da resistividade), densidade (RHOB – detecta os raios gama defletidos pelos elétrons orbitais dos elementos componentes das rochas, após terem sido emitidos por uma fonte colimada situada dentro do poço) e porosidade neutrônica (NPHI – mede a quantidade de nêutrons epitermais e/ou termiais da rocha após o bombardeio) (Thomas, 2001; Doveton, 1994).

Os dados de perfis estavam no formato LAS, que é composto basicamente por um cabeçalho contendo informações sobre o poço e por colunas numéricas, em que cada coluna representa um perfil, com exceção da primeira, que indica a profundidade em que a propriedade foi medida. Os dados de testemunho estavam no formato ANASETE, que consiste de uma representação gráfica contendo as informações retiradas do testemunho.

3.2. Pré-processamento

Para realizar os experimentos, os dados de perfis precisavam ser associados aos dados de testemunho. Para isto, um novo conjunto de dados foi criado contendo os perfis dos 8 poços selecionados (sem o cabeçalho) e as litofácies correspondentes a cada profundidade, obtidas manualmente a partir dos testemunhos.

Embora todos os valores dos perfis fossem numéricos, foi necessário fazer uma discretização dos mesmos para que eles ficassem padronizados, pois cada perfil estava em um intervalo diferente. Os valores foram normalizados para o intervalo [0, 1]. O seguinte cálculo foi realizado para cada valor de perfil (DT, GR, ILD, NPHI e RHOB), bem como para cada valor de profundidade:

$$\text{ValorNormalizado do Perfil} = \frac{\text{ValorPerfil} - \text{menorPerfil}}{\text{maiorPerfil} - \text{menorPerfil}} \quad (1)$$

em que *menorPerfil* e *maiorPerfil* representam o menor e o maior valor do perfil em toda a base de dados, respectivamente.

Segundo White et al. (1995), não é possível identificar as litofácies de um reservatório usando apenas os perfis dos poços. Desta forma as inclinações das curvas nos gráficos dos perfis com relação ao ponto (profundidade) anterior e posterior foram adicionadas aos dados. Para calcular as inclinações das curvas foi utilizada a derivada discreta em cada ponto, conforme as Equações 2 e 3. Todos os valores das inclinações foram discretizados da mesma forma que os perfis.

$$\text{InclinaçãoAnterior} = \frac{\text{ValorPerfil}_i - \text{ValorPerfil}_{i-1}}{\text{Profundidade}_i - \text{Profundidade}_{i-1}} \quad (2)$$

$$\text{InclinaçãoPosterior} = \frac{\text{ValorPerfil}_i - \text{ValorPerfil}_{i+1}}{\text{Profundidade}_i - \text{Profundidade}_{i+1}} \quad (3)$$

em que ValorPerfil_i representa o *i*-ésimo valor do perfil.

Existem 22 tipos de litofácies nos testemunhos dos poços selecionados, no entanto apenas 19 foram utilizadas. As litofácies foram discretizadas de forma que a saída da Rede Neural fosse binária, cada número representando um

tipo de litofÁCie, onde o i -ésimo número representa a litofÁCie i . Por exemplo, a 20ª litofÁCie foi representada por 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0.

4. Experimentos e Resultados

O modelo utilizado no treinamento das Redes Neurais foi o *Multilayer Perceptron* com algoritmo *Backpropagation* (Haykin, 1999). A Figura 1 ilustra a arquitetura geral das redes utilizadas. Os atributos de entrada são os valores dos perfis e as inclinações das curvas nos gráficos com relação ao ponto (profundidade) anterior e posterior. As saídas são as litofÁCies.

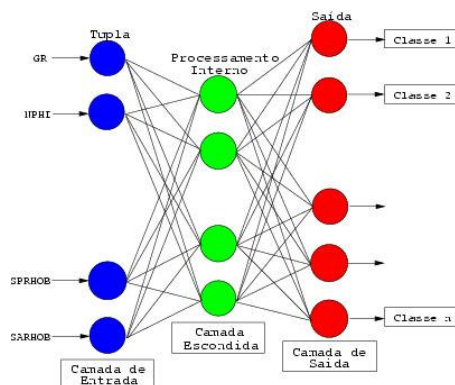


Figura 1 – Arquitetura geral das redes utilizadas.

Várias redes foram construídas visando atingir um bom índice de aprendizagem. Para a construção da arquitetura neural foi utilizado um simulador de Redes Neurais, o SNNS (*Stuttgart Neural Network*) (SNNS). Dos 8 poços selecionados, 5 foram utilizados para treinamento e 3 para teste. O conjunto de dados era composto por 1354 padrões de treinamento e 740 padrões de teste.

Primeiramente, todas as litofÁCies foram utilizadas. A rede era composta de 16 neurônios na camada de entrada, 16 neurônios na camada escondida e 22 neurônios na camada de saída. Observou-se que o erro máximo de treinamento esperado (da ordem de 0.1) não foi alcançado mesmo após um número muito grande de iterações (da ordem de 100000) e por conseqüência o conjunto de teste não chegou a ser utilizado. O erro foi definido como sendo a soma dos quadrados das diferenças entre as saídas reais e desejadas (*average SSE - Sum of Squared Errors*). Para este conjunto de treinamento o SSE por unidade de saída ficou igual a 222,45.

Este resultado inicial ocorreu devido ao alto nível de detalhamento das litofÁCies, à imprecisão da associação dos testemunhos aos perfis e ao diferente número de padrões de cada litofÁCie. Para resolver estes problemas, decidiu-se fazer um agrupamento das litofÁCies relacionadas. Para os experimentos que se seguem, a arquitetura da rede tinha 16 neurônios na camada de entrada, 10 neurônios na camada escondida e foram realizadas 100000 iterações de treinamento.

O primeiro experimento foi realizado com apenas duas litofÁCies (litofÁCie 8 versus litofÁCie 17), portanto a camada de saída da rede tinha 2 neurônios, cada um representando uma classe. As litofÁCies foram escolhidas de acordo com o número de padrões disponíveis de cada litofÁCie. As litofÁCies mais populosas no conjunto foram escolhidas primeiro. Para o conjunto de dados com apenas duas litofÁCies haviam 509 padrões de treinamento e 327 padrões de teste. A Tabela 1 mostra o SSE por unidade de saída após o término do treinamento (SSE/o-units), a taxa de acerto no conjunto de treinamento (Acerto no treinamento) e a taxa de acerto no conjunto de teste (Acerto no teste) em porcentagem.

Tabela 1 – Resultado do treinamento com 2 litofÁCies. vs = versus

| | |
|-----------------------|-------------|
| LitofÁCies | (8) vs (17) |
| SSE/o-units | 1,00053 |
| Acerto no treinamento | 99,80 % |
| Acerto no teste | 67,89 % |

A taxa de acerto no conjunto de treinamento não foi de 100 % porque a rede não conseguiu treinar um padrão. Ao consultar os dados originais, observou-se que este padrão pertencia a uma zona de transição de litofÁCies. Quando as camadas da formação são muito finas, estas podem sofrer interferência das camadas adjacentes, fazendo com que suas propriedades sejam semelhantes. Esta interferência também ocorre nas zonas de transição de uma camada para outra. Como estavam sendo utilizadas apenas duas litofÁCies, a litofÁCie adjacente ao padrão problemático não estava no

conjunto. Para resolver este problema o padrão foi removido e a rede foi treinada novamente. Os resultados são mostrados na Tabela 2.

Tabela 2 – Resultado do treinamento com 2 litofácies após a remoção do padrão problemático. vs = versus

| | |
|-----------------------|-------------|
| Litofácies | (8) vs (17) |
| SSE/o-units | 0,00107 |
| Acerto no treinamento | 100 % |
| Acerto no teste | 70,03 % |

Após a rede ter treinado com uma taxa de acerto de 100 %, a terceira classe mais populosa foi incluída no conjunto de treinamento (litofácia 13). A cada nova litofácia inserida no conjunto de treinamento, vários experimentos eram realizados com as combinações possíveis de agrupamento de modo a determinar qual o grupo com o melhor resultado. A rede que obteve melhor resultado foi agrupando a litofácia 13 com a litofácia 17. Para o conjunto de treinamento contendo o melhor agrupamento de litofácies, constatou-se que alguns dos padrões problemáticos ou estavam em uma zona de transição, ou pertenciam a uma camada muito fina. Conseqüentemente, decidimos alterar a classe associada a esses padrões problemáticos de forma que passassem a pertencer à classe adjacente. Os padrões problemáticos possuindo classes adjacentes (litofácies) que não pertenciam ao conjunto de treinamento foram removidos. A Tabela 3 mostra o resultado do treinamento após o conjunto de treinamento ter sofrido as alterações necessárias.

Tabela 3 – Resultado do treinamento com 3 litofácies agrupadas em 2 classes, após o tratamento dos padrões problemáticos. vs = versus

| | |
|-----------------------|------------------|
| Litofácies | (8) vs (17 e 13) |
| SSE/o-units | 0,00223 |
| Acerto no treinamento | 100 % |
| Acerto no teste | 79,10 % |

A melhor combinação de litofácies quando a litofácia 12 (quarta litofácia mais populosa no conjunto de dados) foi inserida no conjunto de treinamento foi o que continha a litofácia 8 em um grupo e as demais em outro grupo. Após o tratamento dos padrões problemáticos, ou seja, remoção de padrões ou re-classificação, para o melhor conjunto de dados a rede foi treinada novamente e os resultados são apresentados na Tabela 4.

Tabela 4 – Resultado do treinamento com 4 litofácies agrupadas em 2 classes, após o tratamento dos padrões problemáticos. vs = versus

| | |
|-----------------------|----------------------|
| Litofácies | (8) vs (17, 13 e 12) |
| SSE/o-units | 0,00204 |
| Acerto no treinamento | 100 % |
| Acerto no teste | 74,53 % |

Quando a quinta e última litofácia foi inserida no conjunto de treinamento (litofácia 6), o melhor resultado foi agrupando a litofácia 6 com a litofácia 8 e mantendo as demais em outro grupo. A Tabela 5 mostra o resultado do treinamento da rede após o tratamento dos padrões problemáticos.

Tabela 5 – Resultado do treinamento com 5 litofácies após o tratamento dos padrões problemáticos. vs = versus

| | |
|-----------------------|--------------------------|
| Litofácies | (8 e 6) vs (17, 13 e 12) |
| SSE/o-units | 0,00337 |
| Acerto no treinamento | 100 % |
| Acerto no teste | 86,65 % |

Os agrupamentos de litofácies realizados durante os experimentos são conhecidos na literatura como eletrofácies (Serra, 1989). As eletrofácies são um conjunto de respostas de perfis que caracterizam uma camada e permitem que ela seja distinguida das outras. A classificação dos perfis dos poços em eletrofácies não requer qualquer subdivisão artificial da população de dados, ou seja, acontece naturalmente com base nas características únicas das medidas dos perfis do poço que refletem minerais e litofácies dentro de um intervalo perfilado (Lee e Datta-Gupta, 1999).

É possível verificar a coerência dos grupos formados nos experimentos através de uma análise das litofácies agrupadas. A Tabela 6 apresenta os nomes das litofácies utilizadas nos experimentos. Nesta tabela, pode-se identificar

que foi criada uma eletrofície composta por arenitos (8 e 6) e outra composta por interestratificados de siltito com marga (17, 13 e 12).

Tabela 6 – Nomes das litofácies utilizadas nos experimentos.

| Litofácies | Nome | Litofácies | Nome |
|------------|--------------------------------|------------|----------------------------------------|
| 6 | Arenito Grosso Amalgamado | 13 | Interlaminado Siltito Argiloso e Marga |
| 8 | Arenito Médio Maciço Gradado | 17 | Marga Bioturbada |
| 12 | Siltito Argiloso Estratificado | | |

Estes agrupamentos podem ser realizados porque alguns tipos de rochas são permeáveis e porosas o suficiente para permitir o acúmulo de petróleo e outras não. A rocha que permite o acúmulo de petróleo é chamada reservatório. Desta forma, os arenitos e calcarenitos podem se constituir rochas-reservatório, além de todas as rochas sedimentares essencialmente dotadas de porosidade intergranular que sejam permeáveis.

5. Conclusões e Trabalhos Futuros

Este trabalho procura atacar os problemas da combinação de dados de perfis com dados de testemunho para a tarefa de identificação de litofácies. A abordagem utilizada para o reconhecimento de litofácies é baseada em Redes Neurais. Com base nos experimentos descritos, podemos concluir que a combinação de perfis e testemunhos de poços de petróleo apresenta muitos problemas, mas que podem ser resolvidos com sucesso. O reconhecimento de litofácies é muito importante para a caracterização de reservatórios e para garantir o sucesso econômico da fase de produção. Neste caso, o conceito de eletrofácies pode ser muito útil.

Como trabalhos futuros pretende-se inserir todas as litofácies no conjunto de treinamento e comparar o desempenho de Redes Neurais Artificiais com outras técnicas tradicionais de identificação de litofácies. Como a técnica de Redes Neurais Artificiais não fornece uma saída compreensível para o usuário, também é objetivo futuro aplicar um algoritmo de extração de regras à saída da Rede Neural.

6. Agradecimentos

Os autores deste trabalho agradecem o apoio financeiro das seguintes organizações: ANP, CTPETRO, FINEP, CTBRASIL.

7. Referências

- COLL, C., JING, X. D., MUGGERIDGE, A. H. Integration of Core and Log Information To Improve the Representation of Small/Medium-Scale Heterogeneity, *SPE Annual Technical Conference and Exhibition*, SPE 56804, 1999.
- DOVETON, J. H. Geologic Log Interpretation, *SEPM Short Course*, No 29, 1994.
- HAYKIN, S. S. Neural Network: A Comprehensive Foundation, Prentice Hall, 2nd edition, 1999.
- LEE, S. H., DATTA-GUPTA, A. Electrofacies Characterization and Permeability Predictions in Carbonate Reservoirs: Role of Multivariate Analysis and Nonparametric Regression, *SPE Annual Technical Conference and Exhibition*, SPE 56658, 1999.
- MOHN, E., BERTEIG, V., HELGELAND, J. A review of statistical approaches to lithofacies determination from well data, *North Sea Oil and Gas Reservoirs. The Norwegian Institute of Technology*, pp. 301-309, 1987.
- SERRA, O. Sedimentary Environments from Wireline Logs, capítulo 5, pp. 85-117, Schlumberger, 1989.
- SNNS. Stuttgart Neural Network Simulator. <http://www-ra.informatik.uni-tuebingen.de/SNNS/>
- THOMAS, J. E. Fundamentos de Engenharia de Petróleo, Interciência, 2001.
- WHITE, A. C., MOLNAR, D., AMINIAN, K., MOHAGHEGH, S., AMERI, S., ESPOSITO, P. The Application of ANN for Zone Identification in a Complex Reservoir, *Eastern Region Conference Proceedings: Society of Petroleum Engineers*, SPE 30977, pp. 27-32, 1995.