

CORRELAÇÃO DE PARÂMETROS DINÂMICOS E ESTÁTICOS PARA A OBTENÇÃO DE PROPRIEDADES DE ROCHAS DE RESERVATÓRIOS DE PETRÓLEO

Myrian C.A. Costa¹, Nelson F.F. Ebecken¹, Lucia D. Dillon² e José A. Soares²

¹COPPE/Universidade Federal do Rio de Janeiro

²CENPES/PETROBRAS

I. Resumo

O presente trabalho tem por objetivo o estudo da correlação de parâmetros dinâmicos e estáticos obtidos da análise de rochas que compõem os reservatórios de petróleo. Os dados dinâmicos são obtidos *in situ*, ou seja, na própria localização das rochas através de diversas técnicas de aquisição de dados. Os dados estáticos são produzidos em laboratório, a partir da análise das mesmas rochas retiradas de seus locais de origem, em condições controladas e com a utilização de técnicas e instrumentos de precisão satisfatória.

Com a obtenção desta correlação torna-se possível a predição confiável de propriedades de rochas de reservatórios de petróleo.

Neste projeto foram utilizadas as técnicas de Inteligência Computacional que permitem extrair informações intrínsecas, e eventualmente escondidas, de dados e seus relacionamentos. As técnicas de Inteligência Computacional agrupam Procedimentos Estatísticos, Redes Neurais, Lógica Fuzzy e Algoritmos Genéticos.

II. Introdução

Foram disponibilizados para este estudo dois grupos de dados cada um extraído de um tipo específico de rocha. Um grupo para a litologia arenito e outro grupo para a litologia calcário. Para os dois grupos os parâmetros levantados foram os mesmos. Alguns parâmetros não estão completamente preenchidos devido a dificuldade intrínseca na obtenção dos dados, já que são localidades difíceis e com custo de aquisição muito alto. O conjunto total de dados possui 101 registros, sendo: 40 para arenito e 61 para calcário. Todas as informações dos parâmetros, tais como nome e unidade, estão descritos na tabela 1 a seguir:

Nome	Tipo	E/S	Descrição	Unidade
POÇO	string	E	identificação do poço	
PROF	numérico	E	profundidade da amostra	metros
PCONF_I	numérico	E	pressão confinante inicial (ensaio)	MPa
PCONF_F	numérico	E	pressão confinante final (desejado)	MPa
VP	numérico	E	velocidade da onda P	m/s
VS	numérico	E	velocidade da onda S	m/s
RHOB	numérico	E	densidade de perfil	g/cc
PHI	numérico	E	porosidade	%
GR	numérico	E	radioatividade gama	°API
RES	numérico	E	resistividade	ohm.m
LIT	numérico	E	litologia (1-calcário; 2-arenito)	
SAT	numérico	E	saturação em água	%
ARG_TOT	numérico	E	argila total	%
TRUP	numérico	S	tensão de ruptura	MPa
POISSON_est	numérico	S	razão de poisson	
YOUNG_est	numérico	S	módulo de young	GPa
SHEAR_est	numérico	S	módulo shear	GPa

Tabela 1 – Informações dos dados disponíveis para este estudo

III. Redes Neurais Artificiais

RNA (Redes Neurais Artificiais) são algoritmos eficientes para a determinação da inter-relação de parâmetros. Com o emprego de algoritmos de redes é possível se obter o grau de influência que a variação de um parâmetro exerce sobre o resultado final. Desta forma também torna-se possível a predição de valores para o parâmetro desejado. Outra utilização bastante difundida para Redes Neurais é a predição de um valor de saída a partir de parâmetros históricos de dados, ou seja, parâmetros coletados anteriormente por longo períodos de tempo.

Uma das etapas mais importantes no emprego de RNAs para a predição de valores é a determinação da configuração da rede que produzirá o melhor resultado. Utilizaram-se neste estudo duas abordagens para a obtenção desta configuração. A configuração da rede através de AG (Algoritmos Genéticos), segue um algoritmo eficiente de escolha de parâmetros internos de rede e do conjunto de entradas, a partir de várias combinações, verificando a adequação de cada uma. A escolha heurística da configuração da rede somente segue recomendações clássicas iniciais e se desenvolve por tentativas de melhores resultados.

Foram realizados vários testes em que foram empregados algoritmos de treinamento de RNAs distintos, além de quantidades de entradas e saídas diversos. Alguns dos resultados obtidos estão aqui apresentados.

A. Predição por *Backpropagation*

Alguns campos foram descartados seguindo o critério de Sensitividade em relação à análise pretendida. Neste procedimento foi utilizado o algoritmo de treinamento supervisionado *Backpropagation* sem realimentação.

Para cada um dos testes abaixo foi realizada uma análise de sensibilidade das entradas e foram obtidos os índices de correlação linear, RMS e acurácia das saídas para o conjunto de treinamento e o conjunto de teste. A análise de sensibilidade permite a determinação do efeito que uma variação em um dado de entrada acarretará no parâmetro de saída. A correlação linear estabelece a relação entre as saídas reais fornecidas e as saídas calculadas pela rede. Saídas perfeitamente correlacionadas apresentam índice com valor 1,0; saídas não correlacionadas apresentam índice com valor 0; e, saídas anti-correlacionadas apresentam índice com valor $-1,0$. RMS é a raiz do erro médio quadrático entre a saída real fornecida e a saída calculada pela rede. Acurácia é a medida da proximidade entre a saída real fornecida e a saída calculada pela rede. Esta proximidade equivale nesses exemplos a diferenças de 20%.

1. Teste com configuração da rede por AG:

A configuração de rede obtida neste teste foi: 8 entradas, 8 unidades escondidas e 4 saídas. Os índices de correlação linear, RMS e acurácia conseguidos para os parâmetros de saída estão listados na tabela 2.

Saídas	Correlação Linear		RMS		Acurácia
	Treinamento	Teste	Treinamento	Teste	
Tensão de Ruptura	0,9507811	0,7664399	25,49905	49,49019	0,9207921
Razão de Poisson	0,8515447	0,4372417	0,08675555	0,09309611	0,7623762
Módulo de Young	0,7649905	0,8224556	3,981819	10,98722	0,9207921
Módulo Shear	-0,4545072	0,4241149	13,04292	4,909572	0,5445545

Tabela 2 – Correlação Linear, RMS e Acurácia das saídas

O gráfico 1 apresenta os valores de saída obtidos para a Tensão de Ruptura.




Gráfico 1 – Comparação entre Trup fornecida e Trup calculada pela rede

2. Teste com configuração heurística da rede:

A configuração de rede obtida neste teste foi: 7 entradas, 4 unidades escondidas e 4 saídas. Os índices de correlação linear, RMS e acurácia conseguidos neste teste se encontram na tabela 3.

Saídas	Correlação Linear		RMS		Acurácia
	Treinamento	Teste	Treinamento	Teste	
Tensão de Ruptura	0,969317	0,7894593	21,02899	45,11803	0,960396
Razão de Poisson	0,8685209	0,4351279	0,08681936	0,1003239	0,7821782
Módulo de Young	0,7712276	0,7657994	3,993197	11,21678	0,9207921
Módulo Shear	-0,4613342	0,6456629	12,35302	4,075234	0,5742574

Tabela 3 – Correlação Linear, RMS e Acurácia das saídas

O gráfico 2 mostra os valores de saída obtidos para a Tensão de Ruptura.




Gráfico 2 – Comparação entre Trup fornecida e Trup calculada pela rede

O gráfico 3 mostra os valores de saída obtidos para o Razão de Poisson.




Gráfico 3 – Comparação entre Poisson estático e Poisson calculado pela rede

O gráfico 4 mostra os valores de saída obtidos para o Módulo de Young.




Gráfico 4 – Comparação entre Young estático e Young calculado pela rede

O gráfico 5 mostra os valores de saída obtidos para o Shear.




Gráfico 5 – Comparação entre Shear estático e Shear calculado pela rede

3. Comparação de resultados

O gráfico 6 exibe um comparativo de todas os modelos, gerados dos resultados obtidos anteriormente e alguns outros, revelando que são bastante coerentes e com pouca variação.




Gráfico 6 – Comparação entre Trup fornecida e todas as previsões

B. Predição por *Backpropagation* modificado

Este algoritmo utiliza um otimizador genético para sintetizar a configuração da rede, treinando e comparando as saídas através de um algoritmo modificado do *Backpropagation* usual.

Os dados fornecidos foram separados em dados de treinamento, com 51 registros, e dados de teste, com 50 registros. Os campos utilizados como entradas foram PCONF_I, VS, RHOB e GR e TRUP como saída.

A rede obtida possui a configuração de 4 entradas, 1 nível escondido com 6 neurônios e 4 saídas. O erro médio absoluto desta configuração durante o treinamento foi 6,2493.

O gráfico 7 apresenta a comparação entre Trup fornecida e Trup obtida através da rede.




Gráfico 7 – Comparação entre Trup fornecida e Trup calculada pela rede

IV. Análise Estatística

Uma regressão linear utilizando-se os dados fornecidos foi realizada para que se possa fazer a análise e comparação dos resultados obtidos no tópico anterior. Os dados foram divididos em dados de treinamento e dados de teste, com respectivamente 71 e 30 registros. Foram utilizados os campos Pconf_I, VP, VS, RHOB e GR como entradas e Trup como saída. A análise de sensibilidade para as entradas está na tabela 4.

Nome	Sensitividade
PCONF_I	0,3865
VP	0,1758
VS	0,1177
RHOB	0,2545
GR	0,0655

Tabela 4 – Campos utilizados como entradas e índice de sensibilidade

O índice RMS obtido para o conjunto de treinamento foi de 30,2667 e para o conjunto de teste foi 26,0667. A comparação dos resultados pode ser observada no gráfico 8.




Gráfico 8 – Comparação entre Trup fornecida e Trup calculada pela regressão

V. Programa Aplicativo

Os resultados obtidos desta análise podem ser utilizados para o desenvolvimento de um aplicativo capaz de prever as propriedades mecânicas de rochas-reservatório para outros poços. Este aplicativo deve ser capaz de receber dados coletados de outros poços, identificar quais deles são necessários à predição, realizar a predição propriamente dita e fornecer as saídas. As saídas devem estar em formato numérico ou formato gráfico. Pode-se prever também uma análise segundo o critério de ruptura de Mohr-Coulomb, gerando a coesão e o ângulo de atrito.

VI. Conclusão

Pelos resultados obtidos, fica claro que é possível obter um modelo preciso, com uma rede de acurácia satisfatória. Um programa gerado a partir deste estudo é perfeitamente indicado para auxiliar na predição de propriedades de rochas em reservatórios de petróleo.

O melhor resultado obtido foi com o Algoritmo de Backpropagation modificado e geração de configuração de rede por Algoritmo Genético. Deve-se ressaltar que resultados mais precisos poderão ser alcançados com a utilização de modelos mais sofisticados que o algoritmo de Backpropagation. Entretanto este recurso foi reservado para a continuidade deste trabalho preliminar.

Devido a reduzida quantidade de dados disponíveis para a análise, a separação dos dados por litologia mostrou ser de pouca utilidade, gerando comportamento não satisfatório durante o treinamento. Com isso as redes obtidas claramente perdem a capacidade de generalização, fundamental para o modelo proposto.

VII. Bibliografia

1. "Advances in Knowledge Discovery and Data Mining", Fayyad, U.M., Piatetsky-Shapiro, G., Smyth, P. and Uthurusamy, R., MIT Press, 1996
2. "C4.5: Programs for Machine Learning", Quinlan, J.R., Morgan Kaufmann Publishers, 1993
3. "Intelligent Miner for AIX; User's Guide", IBM Corp., 1996
4. "NeuralWorks Predict", Neural Ware Inc., 1997
5. "Neuro Genetic Optimizer", Bio Comp Systems Inc., 1998
6. "NeuroShell 2", Ward Systems Group Inc., 1993
7. "Solving Data Mining Problems through Pattern Recognition", Kennedy, R.L., Lee, Y., Van Roy, B., Reed, C.D. and Lippman, R.P., Prentice Hall Ptr, 1997

Currículo Resumido dos Autores:

Myrian C.A. Costa

Engenheira Eletrônica pela UFRJ em 1984, M.Sc. em Engenharia de Sistemas pela COPPE/UFRJ em 1990 e D.Sc. em Computação de Alto Desempenho, área de Sistemas Computacionais pela COPPE/UFRJ em 1999. Atualmente desenvolvendo pesquisas com Data Mining em Computadores de Alto Desempenho através da Fundação COPPETEC.

Nelson F.F. Ebecken

Professor Titular do Programa de Engenharia Civil da COPPE/UFRJ, Engenheiro Civil em 1970 pela Universidade Federal Fluminense, M.Sc. em 1973 pela COPPE/UFRJ e D.Sc. em 1977 pela COPPE/UFRJ. Participa, como titular, de 05 sociedades científicas nacionais e internacionais.

Lúcia Duarte Dillon

Bacharel em Física pela UFRJ em 1978, M.Sc. em Física do Estado Sólido pela UFRJ em 1984. Geofísica pesquisadora da PETROBRAS, atualmente desenvolve doutoramento no Instituto de Geociências da UFRJ.

José Agnelo Soares

Engenheiro de Minas pela UFPB em 1990 e M.Sc. em Geofísica de Poço pela UFPA em 1992. Geofísico da FADESP, atua junto ao Centro de Pesquisas da PETROBRAS nas áreas de avaliação física de formações geológicas e de aplicações geofísicas para a engenharia de poço.