

PREVISÃO DE SÉRIE TEMPORAL DE SINAIS SÍSMICOS AVO UTILIZANDO REDES NEURAIS

DICKSON NASCIMENTO DANTAS*, HAROLD IVAN ANGULO BUSTOS*, MARCELINO PEREIRA DOS SANTOS SILVA*, CLÁUBIO LANDNEY LIMA BANDEIRA*

* *UERN - Universidade do Estado do Rio Grande do Norte
Mossoró, RN, Brasil*

Emails: dicksondantas@yahoo.com.br, haroldivan@hotmail.com, prof.marcelino@gmail.com, claubiobandeira@gmail.com

Abstract— In an oil reservoir in production, the fluids are in constant movement due to several factors, such as the use of recovery methods that aim maintaining and even increasing the recovery of oil and gas from reservoir. The recovery methods seek to preserve reservoir pressure and move the oil to the producing well, but most of the oil tends to move to other subsurface layers and not just to the wells. Thus, a solution capable of predict future positions of these fluids is very important for petroleum industry. We present algorithms that execute this task using time series forecasting methods based on neural networks. Time-lapse image differences from real AVO signal seismic data were used to validate them.

Keywords— Fluid Prediction, Time Series Forecasting, Neural Networks, Image Processing

Resumo— Em um reservatório de óleo em produção, os fluidos estão em constante movimento devido a vários fatores, tais como a utilização métodos de recuperação que visam manter e até mesmo aumentar a recuperação de petróleo e gás do reservatório. Os métodos de recuperação visam preservar a pressão do reservatório e mover o óleo para o poço de produção, mas a maior parte do óleo tende a mover-se para as outras camadas do subsolo e não apenas para os poços. Assim, uma solução capaz de prever posições futuras destes fluidos é muito importante para a indústria do petróleo. Nós apresentamos algoritmos que executam essa tarefa usando métodos de previsão de séries temporais com base em redes neurais. Foram utilizados diferenças de imagem em lapso de tempo a partir de dados sísmicos reais de sinal AVO para validá-los.

Palavras-chave— Predição de Fluidos, Previsão de Séries Temporais, Redes Neurais, Processamento de Imagens

1 Introdução

Em um reservatório de petróleo em regime de produção, os fluidos estão em constante movimento. Este fato ocorre, principalmente, devido à redução da pressão interna do reservatório, causando um declínio da produção. Assim, diversas técnicas são utilizadas com o objetivo de manter e até mesmo aumentar a recuperação de hidrocarbonetos (petróleo e gás), contidos no interior do reservatório.

Uma forma de aumentar a produção é através de métodos de recuperação onde, através da injeção de água ou gás dentro do reservatório, o aumento de pressão desloca o óleo para o poço produtor. O problema é que parte do óleo tende a mover-se também para outras camadas distantes do poço produtor. Então, é importante monitorar o deslocamento e prever a posição de fluidos no reservatório, evitando custos com prospecção e perfuração de poços em local inadequado.

Sísmica no lapso de tempo, ou sísmica 4D, são dados sísmicos 2D ou 3D obtidos nas mesmas condições em diferentes intervalos de tempo. Na sísmica 4D, a diferença entre dois sinais sísmicos adquiridos em diferentes intervalos de tempo através das mesmas condições de aquisição podem fornecer informações sobre a variação de propriedades geofísicas devido à produção de hidrocarbonetos. No entanto, o processo de subtração exibe energia residual falsa, que não está relacionada com o si-

nal de lapso de tempo, tal como o ruído aleatório, um ruído relacionado com a aquisição e a variação da largura de banda do sinal. Esta energia muitas vezes limita a resolução do sinal de 4D. (Vedanti et al., 2009)

O método de obtenção das imagens deste artigo é conhecido como AVO (Amplitude Variation with Offset - Variação de Amplitude com o Afastamento), que é um método de inversão baseado em dados de sinais sísmicos. A partir do sinal AVO, vários métodos podem ser propostos para estimar a localização do óleo no reservatório. Trabalhos relacionados podem ser vistos em Xie et al. (2011a) e Xie et al. (2011b), que usam métodos para destacar a localização de reservatório de óleo com análise de sinais AVO.

Os dados adquiridos no lapso de tempo são analisados na forma de série temporal, onde, com base nas imagens geradas no passado, é possível gerar uma imagem de tempo futuro, ou seja, a previsão de dados futuros da série temporal.

Este artigo propõe três estratégias de previsão. A primeira, baseada em regressão linear, que é um método numérico que ajusta o resultado futuro com base em uma reta. A segunda estratégia, que é baseada em uma rede neural Multilayer Perceptron, faz o ajuste de função linear ou não-linear com base em treinamento da rede com dados da série temporal. A terceira estratégia, que é semelhante à segunda, faz o mesmo ajuste de função,

mas não para pixels no domínio do espaço, e sim para coeficientes no domínio DCT.

2 Métodos de Previsão da Série Temporal

Séries temporais podem ser definidas como um conjunto de observações geradas sequencialmente no tempo. O processo de previsão das séries temporais consiste em, através das observações de eventos passados, gerar previsões de eventos futuros. Prever eventos futuros geralmente é um trabalho de baixa precisão, pois o processo pode envolver atributos que ocorrem aleatoriamente, tais como ruído de aquisição de dados e ainda outros eventos que podem ocorrer num intervalo mais curto que a amostragem da série.

Contudo, previsões com um grau aceitável de certeza podem ter grande relevância, pois uma previsão pode direcionar os processos de prospecção para locais onde há maior probabilidade de localização de petróleo, reduzindo-se assim os custos.

A previsão em 1D é bastante utilizada na forma de aproximação de funções, onde os dados passados são aproximados em uma função e os dados futuros são obtidos dessa função. Já no caso de imagens, o processo de previsão depende de um enorme conjunto de probabilidades, onde regiões (conjunto de pixels) podem crescer ou se deslocar para quaisquer direções. Esse problema ocorre sempre quando o conjunto de entradas é muito grande em relação ao conjunto de saídas e ao conjunto de treino, o que é conhecido como maldição da dimensionalidade (Haykin, 1999).

Assim, uma forma de se amenizar o problema da dimensionalidade é tratando cada pixel na série temporal como uma função em 1D, de forma que a variação na intensidade do pixel é aproximada nesta função. Outra estratégia de extrapolação, com redução da dimensionalidade, é aplicando a transformada DCT e extrapolando os coeficientes, depois a transformada inversa gera a imagem extrapolada. Detalhes dos métodos de previsão são descritos a seguir.

2.1 Previsão por Regressão Linear

O algoritmo de regressão linear do Weka (Weka, 2013) é baseado numa função linear, sendo uma soma de pesos dos atributos de entrada.

A equação de regressão linear é dada a seguir:

$$y = w_1x_1 + w_2x_2 + \dots + w_nx_n + c \quad (1)$$

onde: y é a saída; $x_1; \dots; x_n$ são as entradas; $w_1; \dots; w_n$ são os pesos; e c é uma constante numérica adicional. A equação de regressão linear requer pelo menos duas entradas, ou seja, dois pixels de tempo passado.

A regressão linear busca uma linha que melhor aproxima os dados de entrada, minimizando a distância média de todos os pontos da linha. Seguindo a linha no tempo, é possível fazer uma estimativa dos pixels futuros. O método baseado em regressão linear é mais preciso quando o comportamento da função se aproxima de uma reta.

2.2 Previsão com Redes Neurais no Domínio do Espaço

O estudo das redes neurais artificiais é motivado pelo fato de que é possível gerar soluções a partir de aprendizado e de generalizar o conhecimento aprendido sem o uso de algoritmos ou regras. Tal abordagem pode ser mais eficiente e eficaz que métodos algorítmicos tradicionais, principalmente em casos onde é necessário ter respostas coerentes para problemas não completamente conhecidos. O problema de previsão de série temporal de sinais AVO se enquadra neste caso, pois o maior conhecimento obtido sobre o reservatório está restrito a dados sísmicos (Braga et al., 2007).

Dentre as diversas arquiteturas de rede neural conhecidas, uma aplicável ao problema deste artigo é a rede neural Perceptron de Múltiplas Camadas (MLP - Multilayer Perceptron), que é um tipo de rede feed-forward de múltiplas camadas. O algoritmo de treinamento aplicado à MLP para extrapolação da série temporal foi o de Levenberg-Marquadt, que é uma aproximação ao método de Newton, sendo uma técnica de otimização mais eficiente que a do gradiente descendente. A regra de atualização peso Levenberg-Marquadt é:

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (2)$$

Na equação 2, J é a matriz jacobiana das derivadas dos erros relacionados aos pesos, μ é um valor escalar e e é um vetor de erros. Se o valor de μ é grande, a expressão acima representa uma descida mais rápida (com passo $1/\mu$), enquanto que, para pequenos valores de μ , a expressão é reduzida para o método de Gauss Newton, que é mais rápido e mais preciso, próximo do erro mínimo. O valor de μ pode aumentar ou diminuir em função da performance ou desempenho.

Os parâmetros da rede neural e do algoritmo Levenberg-Marquadt são os seguintes: neurônios na camada intermediária: 5; função de ativação da camada intermediária: sigmóide; Nº máximo de épocas de treinamento: 500; Meta de performance: 0; Gradiente mínimo: $1e^{-10}$; μ inicial: 0.001; μ fator de decremento: 0.1; μ fator de incremento: 10; μ máximo: $1e^{10}$.

Com este método, a intensidade de um pixel, na mesma posição de cada imagem, forma uma função do nível de cinza da série temporal. Então, a rede neural é treinada com os quatro primeiros pixels, extrapolando o quinto pixel. Com

esta metodologia, objetiva-se aproximar uma função da variação no nível de cinza em cada pixel. Porém, este método é restrito apenas a mudanças locais.

O treinamento é feito da seguinte forma: formam-se conjuntos com duas entradas e uma saída, sendo a saída equivalente à previsão com base nos dois valores anteriores (entradas). A extrapolação de 13 meses foi feita com conjuntos de uma entrada e uma saída, devido ao baixo número de exemplos disponíveis.

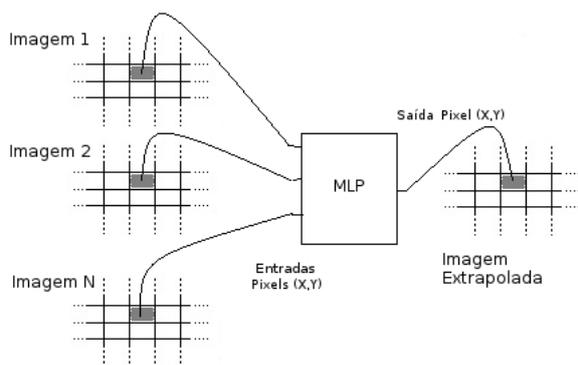


Figura 1: Método de extrapolação no domínio do espaço com rede MLP. A MLP tem como entradas os pixels das imagens de tempo passado, resultando numa saída (pixel) de tempo futuro. O mesmo processo é repetido para cada pixel.

2.3 Previsão com Redes Neurais no Domínio DCT

Este método é semelhante ao primeiro método, porém, ao invés de extrapolar um pixel na série temporal, é extrapolado um coeficiente no domínio DCT. Para isso, foi aplicada a transformada DCT sobre todas as imagens. A seguir, a rede neural é treinada com os pixels das quatro primeiras imagens (coeficientes do domínio DCT), extrapolando o pixel da quinta imagem (coeficiente no domínio DCT). Depois é feita a transformada inversa da imagem extrapolada.

Com o método de previsão no domínio DCT, espera-se obter uma previsão que não seja restrita a apenas um pixel. Ou seja, cada coeficiente no domínio DCT interfere com todos os pixels da imagem no domínio do espaço. Com isso, podem ser extrapolados outros aspectos da série temporal, como por exemplo, crescimento de regiões e deslocamentos.

A Transformada Discreta do Cosseno (DCT - Discrete Cosine Transform) é uma técnica que converte um sinal (1D ou 2D) em componentes de frequências elementares. Com a aplicação da DCT, grande parte da energia dos dados é armazenada em poucos coeficientes. Entre as principais aplicações da transformada discreta do cos-

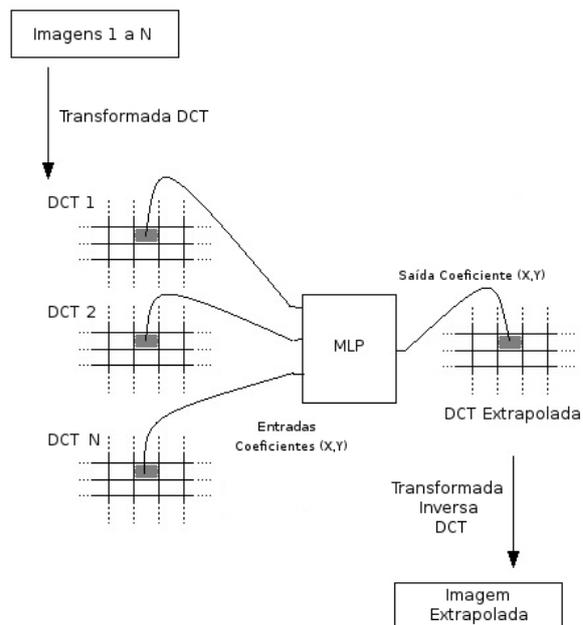


Figura 2: Método de extrapolação no domínio DCT com rede MLP. A MLP tem como entradas os coeficientes das imagens no domínio DCT de tempo passado, resultando numa saída (coeficiente) de tempo futuro. O mesmo processo é repetido para cada coeficiente. A seguir, é feita a transformada inversa, obtendo-se a imagem de tempo futuro no domínio do espaço.

seno pode-se mencionar: codificação e filtragem de imagens, reconhecimento de padrões e extração de características (Khayam, 2003).

A definição da DCT bidimensional de uma imagem de entrada em uma imagem B de saída é um processo bem conhecido na literatura, definido, entre outros autores por (Gonzalez and Woods, 2008).

3 Dados e Metodologia

Neste artigo, foram usadas imagens no lapso de tempo do campo de Duri, na Indonésia. As imagens são pré-processadas por co-registro (Fomel, 2007). O co-registro pode ser definido como a sobreposição de duas ou mais imagens (uma imagem base e uma imagem monitor), de modo que há correspondência entre seus pontos. Estas imagens contêm dois efeitos distintos com o decorrer do tempo: mudanças nas imagens causados por mudanças nas velocidades sísmicas e diferenças de amplitude causadas por mudanças na refletividade sísmica (Fomel and Long, 2007). No campo de Duri, a imagem base foi adquirida antes da injeção de vapor e as outras cinco imagens foram registradas com uma média de quatro meses, que variam de 2 a 19 meses após a injeção de vapor. Dadas as propriedades químicas do vapor, a tendência é que este se mova junto com o óleo e gás

para o topo do reservatório, uma vez que estes têm uma densidade mais baixa.

Além disso, a técnica de injeção de vapor permite realçar o reservatório nas secções sísmicas devido ao forte contraste com os outros artefatos encontrados no interior do reservatório devido às suas propriedades de alta impedância às ondas sísmicas. Assim, torna-se visivelmente mais fácil de identificar áreas de interesse, isto é, as áreas que podem conter hidrocarbonetos, depois da injeção de vapor, nas seqüências sísmicas.

A localização do topo do reservatório principal, que é representada no tempo, está a cerca de 160 ms e a base, um pouco abaixo, com 200 ms (Lumley, 1995). Esta área corresponde a região de interesse a ser monitorada. Assim, outras regiões da imagem pode ser removidas. Além disso, para reduzir as limitações computacionais de processamento de imagem, foi selecionado um ponto de corte para as imagens (entre 150 ms e 210 ms), onde foram aplicadas as técnicas de previsão. A Figura 1 mostra secções sobre todas as seqüências utilizadas.

Estes dados correspondem à variação da amplitude acústica refletida pelas camadas do subsolo para a superfície (onde são captadas pelos sensores) com o afastamento (distância entre a fonte e os sensores). Este sinal é denominado AVO, onde nele, normalmente a amplitude registrada decresce com o afastamento, e na presença de gás ocorre, porém, um crescimento anômalo. Esta anomalia é produzida pela descontinuidade e diminuição brusca da impedância acústica geradas devido à passagem das ondas sísmicas das camadas sólidas para as camadas contendo gás no reservatório. Mediante este comportamento, dá-se a importância da análise de AVO como instrumento para detecção direta de hidrocarbonetos.

Na Figura 3, a cor azul representa regiões de baixa impedância acústica, sendo essas regiões associadas à interface entre a base do reservatório e as outras camadas inferiores. Já a cor vermelha representa regiões de alta impedância acústica, sendo essas regiões associadas à interface entre o topo do reservatório (com o vapor injetado) e camadas superiores.

Para verificar a eficácia dos algoritmos propostos, tentamos extrapolar a seqüência sísmica conhecida. Ou seja, extrapolamos as imagens de 13 e 19 meses usando a seqüência das imagens anteriores. Para isso, foram utilizados os métodos de extrapolação por regressão linear e redes neurais. Vale salientar que, devido à baixa quantidade de imagens, temos um pequeno conjunto de treinamento. Portanto, o método de extrapolação com redes neurais foi restrito apenas a um pequeno conjunto de treinamento com as imagens conhecidas.

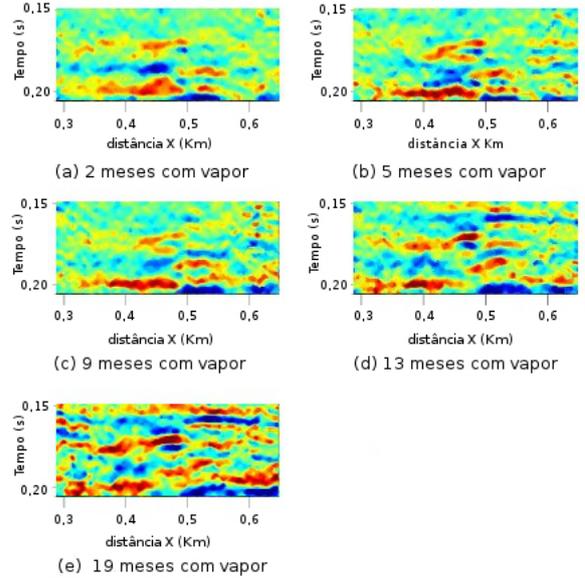


Figura 3: Imagens AVO do Campo de Duri após o co-registro. O recorte destaca apenas a região principal do reservatório. Adaptado de Fomel and Long(2007).

4 Resultados

Duas extrapolações da série temporal resultaram em uma imagem equivalente ao sinal AVO de 13 e 19 meses após a injeção de vapor. Para avaliar esse resultado, são propostos os seguintes métodos: erro MAE e classificação das porcentagens de impedâncias.

O erro MAE é representado pela equação 3, em que x_i é o valor verdadeiro, y_i correspondem aos dados previstos e N representa o número total de classificações consideradas na predição. O valor é dado em porcentagem. Quanto maior a diferença entre as imagens, mais próximo de 100%.

$$MAE = \frac{1}{n} \sum_{i=1}^N |x_i - y_i| \quad (3)$$

O resultado do cálculo do erro MAE para a imagem real de 13 meses e as imagens extrapoladas é mostrado na tabela 1. O erro máximo obtido é de 100%.

Tabela 1: MAE (%) calculado entre as imagem de 13 e 19 meses e as extrapoladas de tempo equivalente

	MLP Espaço	MLP com DCT	R. Linear
13	13.55%	13.73%	13.16%
19	11.93%	13.03%	14.19%

A outra forma de avaliar a diferença entre a imagem real e a extrapolada é pelo cálculo das

porcentagens das impedâncias acústicas. Nas imagens, os pixels são classificados em três faixas de valores: impedância alta (pixels vermelhos), impedância baixa (pixels azuis), impedância de fundo (intervalo entre vermelho e azul).

As Figuras 4 e 5 mostram o resultado da extrapolação correspondente a 13 e 19 meses com vapor, respectivamente. Na Figura 5, (a) é a imagem original do lapso de tempo, (b) representa a imagem extrapolada por redes neurais com a transformada DCT, (c) representa a imagem extrapolada por redes neurais no domínio do espaço e (d) representa a extrapolação por regressão linear.

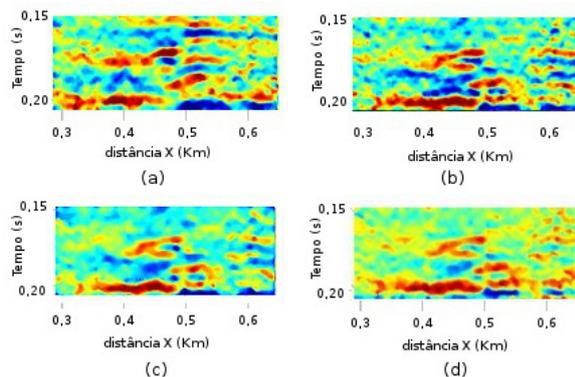


Figura 4: Sequência sísmica de 13 meses com vapor. (a) Imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

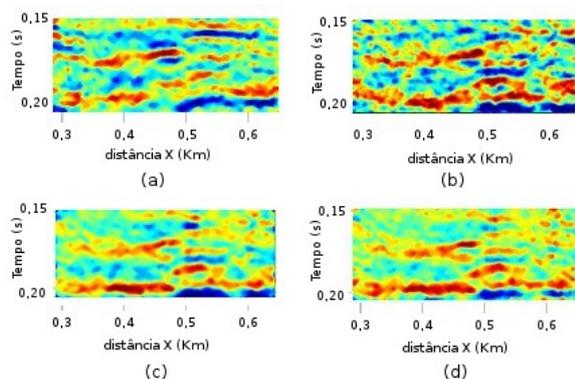


Figura 5: Sequência sísmica de 19 meses com vapor. (a) Imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

As porcentagens das impedâncias de 13 meses e 19 meses são exibidas nos gráficos das Figuras 6 e 7, respectivamente, onde pode-se notar que o resultado que mais se aproximou, em porcentagens,

foi a extrapolada por rede neural MLP no domínio DCT. As Tabelas 2 e 3 mostram as porcentagens de impedâncias para as imagens de 13 e 19 meses, respectivamente.

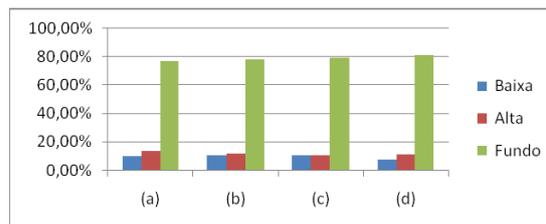


Figura 6: Gráfico com as impedâncias da imagem de 13 meses: (a) imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

Tabela 2: Porcentagens de impedâncias acústicas associadas à imagem de 13 meses após a injeção de vapor e as extrapoladas de tempo equivalente: (a) imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

13 meses	Alta	Baixa	Fundo
(a)	13,58%	9,48%	76,93%
(b)	11,67%	10,17%	78,14%
(c)	10,21%	10,40%	79,38%
(d)	11,09%	7,21%	81,33%

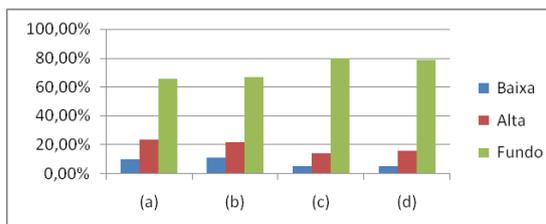


Figura 7: Gráfico com as impedâncias da imagem de 19 meses: (a) imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

Para avaliar a performance da rede neural, foram feitas várias simulações com os mesmos parâmetros. Isto é importante, pois a rede neural é sensível aos valores iniciais dos pesos. Depois, os resultados foram combinados por média aritmética dos níveis de cinza em cada pixel. A seguir, foi calculado o desvio padrão dos resultados de cada simulação.

Por exemplo, com 6 simulações da sequência sísmica de 19 meses no domínio do espaço, temos

Tabela 3: Porcentagens de impedâncias acústicas associadas à imagem de 19 meses após a injeção de vapor e as extrapoladas de tempo equivalente: (a) imagem original, (b) Extrapolada por rede neural MLP no domínio da transformada DCT, (c) Extrapolada por rede neural MLP no domínio do espaço, (d) Extrapolada por regressão linear

19 meses	Alta	Baixa	Fundo
(a)	23.89%	10.35%	65.75%
(b)	21.76%	11.41%	66.82%
(c)	14.37%	5.50%	80.12%
(d)	15.92%	5.46%	78.60%

os seguintes valores de média dos níveis de cinza: 134,83; 134,60; 135,00; 135,07; 134,63; 134,70. Para esses resultados, o desvio-padrão é de 0,20.

Com 6 simulações da sequência sísmica de 19 meses no domínio DCT, temos os seguintes valores de média dos níveis de cinza: 131,99; 133,53; 132,96; 133,94; 132,72; 131,89. Para esses resultados, o desvio-padrão é de 0,82.

5 Conclusões

Este trabalho teve por objetivo criar um modelo de previsão numérico computacional da distribuição espacial e temporal da permeabilidade dos fluidos em meios porosos tal como um reservatório de petróleo. Conhecendo este modelo é possível prever inteligentemente para onde o petróleo se desloca quando parte dele é extraído para a superfície via poços de produção.

É conhecido que somente 30% do petróleo no subsolo é passível de ser recuperado a partir dos poços. Assim, 70% do petróleo fica sem ser recuperado e explorado comercialmente.

Portanto, uma questão que fica em aberto de grande interesse para indústria de petróleo é poder detectar e monitorar os 70% do óleo que fica armazenado no subsolo.

A ideia por trás deste trabalho foi desenvolver uma aproximação numérico computacional capaz de prever e mapear inteligentemente os fluidos de um reservatório visando monitorar o movimento desses fluidos no interior do meio poroso. Fazendo isto pode-se localizar e prever de forma exata a posição dos fluidos no interior do subsolo, podendo-se aumentar assim, a margem ou porcentagem de fluidos passível de ser recuperado.

Conclui-se que as metodologias com redes neurais para o previsão de séries temporais em geral obtiveram menor erro, mesmo nas condições de baixa resolução temporal e pequeno conjunto de treinamento (apenas 5 imagens, sendo a última para validação). No caso da rede neural no domínio do espaço, esta mostrou bons resultados para avaliar mudanças locais na série temporal. Já a rede neural no domínio DCT mostrou-se melhor

para avaliar mudanças globais, tais como crescimento de regiões, onde o resultado das porcentagens de impedância acústica foram próximos da imagem real.

Agradecimentos

Os autores agradecem à FAPERN pelo apoio financeiro.

Referências

- Braga, A. P., de Carvalho, A. C. P. L. and Luder-mir, T. B. (2007). *Redes Neurais Artificiais: Teoria e Aplicacoes*, 2 edn.
- Fomel, S. (2007). Local seismic attributes, *Geophysics* **72**(3): A29–A33.
- Fomel, S. and Long, J. (2007). Time-lapse image registration using the local similarity attribute, *77th Annual International Meeting* pp. 2979–2983.
- Gonzalez, R. C. and Woods, R. E. (2008). *Digital image processing*, 3 edn, Prentice Hall, Upper Saddle River, N.J.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall.
- Khayam, S. A. (2003). *The Discrete Cosine Transform (DCT): Theory and Application*, Department of Electrical & Computer Engineering, Michigan State University.
- Lumley, D. E. (1995). 4-d seismic monitoring of an active steamflood, *65th Ann. Internat. Mtg, Soc. of Expl. Geophys.* pp. 203–206.
- Vedanti, N., Pathak, A., R.P.Srivastava and V.P.Dimri (2009). Time Lapse (4D) Seismic: Some Case Studies, *Earth Science India Vol.2 (IV)*(ISSN: 0974 - 8350): 230 – 248.
- Weka (2013). Weka Machine Learning Project. <http://www.cs.waikato.ac.nz/ml/weka/>.
- Xie, K., Yu, W., Yu, H., Wu, P., Li, T. and Peng, M. (2011a). An AVO Inversion Algorithm Base on Time-Lapse Seismic Data, *Intelligence Science and Information Engineering (ISIE), 2011 International Conference on*, pp. 133–136.
- Xie, K., Yu, W., Yu, H., Wu, P., Li, T. and Peng, M. (2011b). Multi-parameter Calibration Algorithm Based on 4D Seismic Inversion, *Intelligence Science and Information Engineering (ISIE), 2011 International Conference on*, pp. 185–188.