

# Predição de Fluidos em um Reservatório Petrolífero Utilizando Métodos de Previsão de Séries Temporais

Harold I. A. Bustos<sup>1</sup>, Marcelino P. S. Silva<sup>1</sup>, Cláudio L. L. Bandeira<sup>2</sup>, Ewerton C. Ribeiro<sup>1</sup>

<sup>1</sup>Departamento de Informática  
Universidade do Estado do Rio Grande do Norte (UERN)

<sup>2</sup>Mestrado em Ciência da Computação  
Universidade do Estado do Rio Grande do Norte (UERN)  
Universidade Federal Rural do Semi-Árido (UFERSA)  
Mossoró – RN – Brasil

haroldivan@hotmail.com, {prof.marcelino,claubiobandeira,ewertonce}@gmail.com

**Abstract.** *The production decline of an oil reservoir is a common and natural thing. Thus, techniques are used with the aim of maintaining and even increasing the recovery of oil and gas from the reservoirs. Among these techniques, it can be highlighted the use of recovery methods that seek to preserve reservoir pressure and move the oil to the producing well. However, most of the oil tends to move to other layers and not just to the wells. Therefore, a solution capable of monitoring this movement and even predict future positions of these fluids is a process very important. We present two algorithms that execute this task using time series forecasting methods. Pre-processed real field data by co-registration were used to validate them.*

**Resumo.** *O declínio da produção de um reservatório é algo comum e natural. Com isso, técnicas são usadas objetivando manter e até mesmo aumentar a recuperação de petróleo e gás dos reservatórios. Dentre elas podemos destacar o uso dos métodos de recuperação que buscam manter a pressão do reservatório e deslocar o óleo para o poço produtor. Porém, a maior parte do óleo tende a deslocar-se para outras camadas e não só para os poços. Assim, uma solução capaz de monitorar este deslocamento e mesmo prever posições futuras desses fluidos é um processo bastante relevante. Apresentamos dois algoritmos que executam tal tarefa usando métodos de previsões de séries temporais. Dados de campo reais pré-processados por co-registro foram utilizados para validá-los.*

## 1. Introdução

O declínio da produção de um reservatório de petróleo é algo comum e natural. Isso ocorre devido à redução da pressão interna do reservatório. Visando manter e até mesmo aumentar a produção são empregadas técnicas que objetivam otimizar a recuperação dos hidrocarbonetos (petróleo e gás) contidos no interior do reservatório. Com isso, pode-se identificar os melhores locais para a perfuração dos poços [Ostrander 1984].

Dentre estas técnicas uma bastante comum é o uso de métodos de recuperação, que têm como finalidade tentar manter a pressão do reservatório e deslocar o óleo para o poço produtor. Isso pode ser feito, por exemplo, injetando-se água ou gás dentro do

reservatório. Todavia, grande parte do óleo tende a deslocar-se para outras camadas e não só para os poços.

Dessa forma, tarefas como monitorar esse deslocamento e mesmo prever posições futuras desses fluidos em rochas reservatórios é uma etapa bastante relevante, evitando assim usos desnecessários dos dispendiosos processos de prospecção. Para tanto, existem metodologias que permitem realizar esta tarefa como o co-registro de imagens, também conhecido como alinhamento geométrico. Este, por sua vez, pode ser utilizado para rastrear o vapor d'água injetado nos poços entre as sequências sísmicas, possibilitando o mapeamento do deslocamento de fluidos no reservatório.

Dentre as técnicas utilizadas para este fim, está a conhecida sísmica 4D que baseia-se na aquisição de dados em lapso de tempo (*time-lapse*) de sucessivas imagens 3D sobre uma mesma área [Nur 1989]. Segundo [Lumley 2010], a sísmica 4D pode ser extremamente útil para monitorar o dióxido de carbono ( $\text{CO}_2$ ) injetado e armazenado em reservatórios geológicos de subsuperfície. Um trabalho neste sentido pode ser visto, por exemplo, em [Risso and Schiozer 2008] que proporam um método integrando o histórico de produção e de pressão com os mapas das frentes de saturação obtidos através da sísmica 4D, permitindo ajustá-los de forma que estes modelos possam ser usados na previsão de produção com maior confiabilidade.

Diante deste cenário, o objetivo deste trabalho é realizar a predição de fluidos que, por sua vez, visa estimar o comportamento futuro de um reservatório. Para tanto, é gerado um modelo numérico de reservatório utilizando métodos de previsão de séries temporais baseados em modelos de regressão linear e polinomial do sinal de interesse a ser monitorado. Dados reais de reservatórios obtidos da base de dados do software Madagascar são submetidos aos algoritmos desenvolvidos para validá-los.

## 2. Predição de Fluidos

Nos poços em regime de produção o volume a ser recuperado tende a cair principalmente em virtude da redução da pressão interna do reservatório. Além disso, da quantidade de petróleo existente nos reservatórios, na prática, apenas uma pequena fração consegue ser retirada [Curbelo 2006].

Com isso, várias técnicas são utilizadas para otimizar a recuperação dos hidrocarbonetos. Dentre as mais utilizadas estão os métodos de recuperação que, por sua vez, têm a finalidade de tentar manter a pressão do reservatório e deslocar o óleo para o poço produtor. Para tanto, isso pode ser feito injetando-se no poço água, gás, vapor d'água dentre outros. No entanto, grande parte do óleo tende a deslocar-se para outras camadas e não só para os poços.

Desta forma, monitorar esse deslocamento e mesmo prever posições futuras desses fluidos em rochas de reservatórios é um processo bastante relevante, uma vez que pode-se assim, direcionar inteligentemente o uso de processos dispendiosos de prospecção. Para abordar este problema, existe a sísmica 4D que, por sua vez, baseia-se na aquisição repetitiva de dados sísmicos em intervalos de tempo. Uma vez coletados, os dados podem ser processados com algoritmos específicos de forma a possibilitar o mapeamento do deslocamento de fluidos no reservatório e até mesmo predizer sua posição futura. A modelagem de fluxo de fluido e sua previsão no tempo pode ser aproximada

através de técnicas de extrapolação, empregando métodos de previsão de séries temporais como regressão linear e polinomial descritos a seguir.

## 2.1. Métodos de Previsão de Séries Temporais

### 2.1.1. Regressão Linear

A equação ajustada pelo modelo de regressão linear simples é dada por:

$$I_1(x, y, t) = a_1(x, y)t + b_1(x, y) \quad (1)$$

Onde  $I_1(x, y, t)$  representa o tom de cinza do pixel associado à amplitude acústica de cada sequência na  $t$ -ésima tentativa, ou observação;  $(x, y)$  correspondem às coordenadas do pixel de interesse para cada sequência sísmica;  $t = 1, 2, \dots, n$  corresponde à variável independente do tempo; o subíndice 1 indica que um ajuste linear entre duas sequências sucessivas da Amplitude versus Afastamento (AVO, do inglês *Amplitude Versus Offset*) foi usado para calcular a extrapolação deste sinal em um tempo futuro posterior à segunda sequência do sinal AVO;  $a_1$  é o coeficiente de regressão (coeficiente angular); e, por fim,  $b_1$  representa o coeficiente linear. Assim,  $a_1$  e  $b_1$  representam os parâmetros do ajuste da regressão linear no tempo. Sendo este um modelo de regressão baseado em um ajuste linear da serie temporal associada ao sinal AVO, então ele encaixa dentro do grande modelo Auto-Regressivo generalizado chamado de (AR) [Wiener 1964], uma vez que o valor futuro da série pode ser obtido a partir de uma combinação linear dos valores passados da mesma.

Para encontrar uma imagem do sinal AVO extrapolada no tempo é necessário ter uma sequência em um determinado período de tempo – a qual corresponde ao instante de tempo inicial, ou seja,  $t = 0$  – e outra sequência em um instante de tempo posterior. Também, é preciso determinar os valores de  $a_1$  e  $b_1$ . Para tanto,  $b_1$  pode ser definido assumindo que  $t$  é igual a 0 sobre a Equação 1. Da mesma forma,  $a_1$  pode ser estimado através da Equação 1 assumindo que  $t$  corresponde ao período de tempo posterior em que é amostrada a segunda sequência do sinal AVO e substituindo o valor de  $b_1$ .

### 2.1.2. Regressão Quadrática

A equação ajustada pelo modelo de regressão quadrática é demonstrada abaixo:

$$I_2(x, y, t) = a_2(x, y)t^2 + b_2(x, y)t + c_2(x, y) \quad (2)$$

Onde:  $I_2(x, y, t)$ , do mesmo modo que  $I_1(x, y, t)$ , representa o tom de cinza do pixel associado à amplitude acústica de cada sequência na  $t$ -ésima tentativa, ou observação; da mesma forma,  $t = 1, 2, \dots, n$  corresponde à variável independente no tempo; porém, o subíndice 2 indica que um ajuste polinomial quadrático entre três sequências sucessivas foi usado para calcular a extrapolação em um tempo futuro posterior à terceira sequência do sinal AVO;  $a_2$ ,  $b_2$  e  $c_2$  são parâmetros da equação quadrática e representam os parâmetros do ajuste da regressão quadrática.

Para encontrar uma imagem extrapolada do sinal AVO usando a regressão polinomial quadrática é necessário ter: uma sequência em um determinado período de tempo, a qual corresponde ao instante de tempo inicial, ou seja,  $t=0$ ; e outras duas sequências em instantes de tempos posteriores diferentes. Da mesma forma, é preciso encontrar os valores de  $a_2$ ,  $b_2$  e  $c_2$ . Para tanto,  $c_2$  pode ser definido assumindo que  $t$  é igual a 0 sobre a Equação 2. Para definir  $a_2$  e  $b_2$ , é necessário resolver o sistema linear que se forma ao substituir os diferentes instantes de tempo posteriores na Equação 2 que estão associados às amostras das séries temporais conhecidas nestes períodos de tempo e substituir o valor de  $c_2$  nelas.

### 3. Resultados

O co-registro (alinhamento geométrico) pode ser definido como a sobreposição de duas ou mais imagens – uma imagem base e uma imagem monitor. Isso pode ser feito mediante algumas operações tais como rotação, translação e escala que posicionam alinhadamente as imagens, gerando uma matriz dessa transformação [Rodrigues 2010].

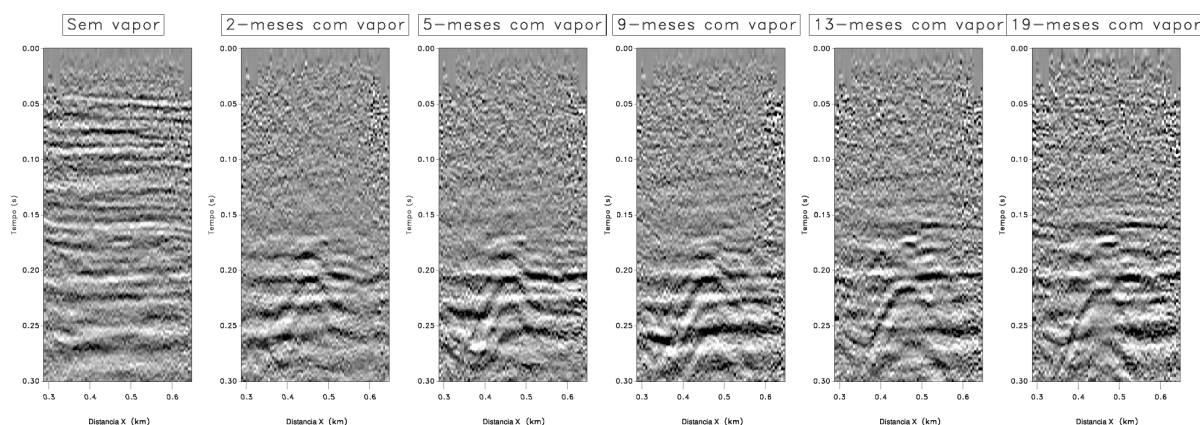
Sobre as aplicações desenvolvidas, foram utilizados dados de campo reais pré-processados por co-registro. Em aplicações sísmica, ele pode permitir o monitoramento dinâmico de fluidos, realçando somente o comportamento do reservatório e possibilitando eliminar grande parte dos artefatos que não pertencem a ele. Tal monitoramento pode ser bastante útil para prever o fluxo futuro dos fluidos nas rochas reservatórios.

A Figura 1 mostra dados *onshore* (de terra) que serão utilizados neste trabalho. Eles representam dados de campo reais para monitoramento de fluidos em Duri, Indonésia após a aplicação do método de co-registro – sobre os registros de 2 a 19 meses [Fomel and Long 2007]. Neste campo, um registro base foi adquirido antes da injeção de vapor d'água e outros cinco registros foram feitos em uma média de intervalos de 4 meses, que varia de 2 a 19 meses após o início da injeção do vapor. A parte superior do reservatório principal está em cerca de 1,6 s e a base está um pouco abaixo dos 2 s [Lumley 1995].

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 [Ostrander 1984].

A última sequência sísmica conhecida é a de 19 meses após a injeção do vapor. Dada a importância de se estimar o comportamento futuro do reservatório, torna-se preciso estimar uma sequência que ainda não se conhece, por exemplo, 23 meses após a injeção de vapor d'água.

Inicialmente, visando verificar a eficiência e o desempenho do algoritmo proposto, buscou-se extrapolar sequências sísmicas conhecidas. Desta forma, procurou-se obter extrapolações para as sequências de 13 e 19 meses utilizando os métodos de regressão




**Figure 1. Sequências sísmicas co-registradas. Adaptado de [Fomel and Long 2007]**

linear e quadrática, definidos pelas equações 1 e 2, respectivamente. Com isso, é possível quantificar numericamente o quão exato é o processo adotado, pois permite comparar as imagens extrapoladas com as próprias.

Assim, as Figuras 2(a), (b) e (c) correspondem aos processos realizados sobre a sequência sísmica de 13 meses, na qual a Figura 2(a) exibe a imagem de 13 meses original, enquanto que na Figura 2(b) tem-se a sequência sísmica obtida pelo processo de extrapolação regressão linear e a Figura 2(c) representa a sequência sísmica obtida pelo processo de extrapolação regressão quadrática.

Já as Figuras 2(d), (e) e (f) correspondem aos processos efetuados sobre a sequência sísmica de 19 meses, onde na Figura 2(d) tem-se a imagem de 19 meses original, na Figura 2(e) tem-se a sequência sísmica obtida pelo processo de extrapolação regressão linear e na Figura 2(f) a sequência sísmica obtida pelo processo de extrapolação regressão quadrática.



**Figure 2. Sequências sísmicas de 13 meses a) original, extrapolada por b) regressão linear e por c) regressão quadrática; e sequências sísmicas de 19 meses d) original, e) extrapolada por regressão linear e f) por regressão quadrática**

Para calcular o nível de semelhanças entre as imagens extrapoladas e a sequência

sísmica real, foi utilizado a biblioteca ProEikon [Kim 2011]. O ProEikon é um pacote de *software* com algoritmos de Processamento e Análise de Imagens e Vídeos (PAIV). Esta biblioteca possui um programa chamado DistG que calcula a diferença entre duas imagens em níveis de cinza, possibilitando assim, quantificar numericamente o quão exatas são as imagens geradas.

O DistG possui dentre outros estimadores o *Mean Absolute Error* (MAE, do inglês Erro Médio Absoluto). Na Estatística, ele é uma grandeza utilizada para medir o quão próximas as previsões e as predições estão dos resultados finais, além de ser uma medida comum de erro de previsão em análise de séries temporais. Desta forma, ele permite avaliar o erro entre os dados previstos pela extrapolação numérica e os dados reais utilizados para gerar o sinal AVO da sequência sísmica amostrada. O MAE é representado pela Equação 3.

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

Sendo  $x_i$  é o valor real obtido,  $y_i$  corresponde aos dados previstos e  $n$  o número de avaliações consideradas.

A Figura 3 exibe as saídas após a execução do algoritmo DistG. Na Figura 3(a) tem-se o resultado da análise entre a imagem de 13 meses após a injeção do vapor d'água e sua extrapolada obtida por regressão linear. Nela, é possível observar que o algoritmo MAE calculou 13,07% de diferença entre as duas imagens, isto é, elas possuem 86,93% de semelhança. Já a Figura 3(b) mostra a saída do DistG sobre a imagem de 13 meses e sua extrapolada por regressão quadrática, onde o algoritmo MAE calculou 14,72% de diferença entre estas duas imagens, ou seja, elas possuem 85,28% de semelhança, resultado inferior ao método de regressão linear.

A Figura 3(c) mostra o resultado da execução deste algoritmo sobre a imagem de 19 meses e sua extrapolada pelo método regressão linear. Nela, é possível observar que o algoritmo MAE calculou 14,19% de diferença entre as duas imagens, ou seja, elas possuem 85,81% de semelhança. Por fim, a Figura 3(d) mostra a saída após a execução do algoritmo DistG sobre a imagem de 19 meses e sua extrapolada pelo método regressão quadrática. Desta vez, o algoritmo MAE calculou 15,64% de diferença entre estas duas imagens, ou seja, elas possuem 84,36% de semelhança. Este resultado também mostra-se inferior ao método de regressão linear.

Intuitivamente, é de conhecimento que o processo de ajuste polinomial da série poderia permitir obter resultados mais exatos na extrapolação do sinal AVO, em relação aos gerados pelo ajuste linear, pois ele utiliza três sequências de dados de entrada quando comparados com apenas as duas sequências de entrada do ajuste linear. Porém os erros calculados para ambas as aproximações dos ajustes são quase similares, tal como é mostrado na Figura 3.

Uma vez testado os métodos para extrapolar uma sequência conhecida, foram utilizados tais métodos para estimar o comportamento do reservatório 23 meses após a injeção do vapor, isto é, uma sequência futura e que ainda não se conhece. Assim, a Figura 4a) a seguir, exibe a extrapolação por regressão linear e a Figura 4b) exibe o resultado da

<pre> img distg 13-months stean.jpg l8.jpg % of different pixels.....: 97.82% MAE (max=100%).....: 13.87% Standard-deviation (max=100%).....: 25.6153% RMSE (max=100%).....: 17.58% SNR (signal-to-noise ratio).....: 9.8122 dB PSNR considering highest=255.....: 15.1817 dB Tempo gasto: 0.83 segundos </pre>	<pre> img distg 13-months stean.jpg i11.jpg % of different pixels.....: 98.14% MAE (max=100%).....: 14.72% Standard-deviation (max=100%).....: 28.7818% RMSE (max=100%).....: 19.57% SNR (signal-to-noise ratio).....: 8.8885 dB PSNR considering highest=255.....: 14.1781 dB Tempo gasto: 0.82 segundos </pre>
a)	b)
<pre> img distg 19-months stean.jpg 19-months extrapolada.jpg % of different pixels.....: 98.11% MAE (max=100%).....: 14.19% Standard-deviation (max=100%).....: 27.8031% RMSE (max=100%).....: 18.71% SNR (signal-to-noise ratio).....: 9.3344 dB PSNR considering highest=255.....: 14.5596 dB Tempo gasto: 0.81 segundos </pre>	<pre> img distg 19-months stean.jpg 19-months quad.jpg % of different pixels.....: 98.33% MAE (max=100%).....: 15.64% Standard-deviation (max=100%).....: 29.5868% RMSE (max=100%).....: 20.43% SNR (signal-to-noise ratio).....: 8.5688 dB PSNR considering highest=255.....: 13.7941 dB Tempo gasto: 0.83 segundos </pre>
c)	d)

Figure 3. Saídas do algoritmo DistG

extrapolação por regressão quadrática desta sequência.

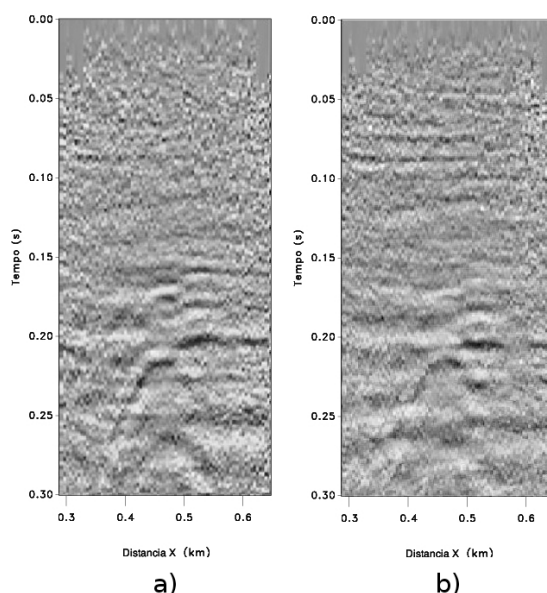


Figure 4. Sequências sísmicas correspondendo a 23 meses após a injeção do vapor extrapoladas por a) regressão linear e b) quadrática

#### 4. Conclusões

A predição do comportamento futuro de um reservatório é uma questão em aberto e é uma área extremamente importante para a indústria petrolífera, pois ela almeja o aumento na recuperação final de hidrocarbonetos. Técnicas para realizar tal tarefa foram propostas neste trabalho empregando métodos de previsões de séries temporais, especificamente regressão linear e regressão quadrática.

Os erros mostrados na Figura 3 e computados por ambos os métodos, evidenciam que o método de ajuste linear descreve melhor o modelo de previsão feito sobre a série espaço temporal do sinal AVO, uma vez que o erro do ajuste linear é menor para ambos os casos se comparado ao erro do ajuste polinomial. Consideramos que tal fato pode ser

explicado devido às sequências do sinal AVO terem sido registradas em intervalos, ou lapsos, de tempo relativamente próximos uns dos outros. Assim, tais sequências apresentam tendências no tempo relativamente idênticas uma das outras. Nesta hipótese, pode ser explicado então porque um ajuste baseado em uma simples regressão linear adquire melhores resultados do que os obtidos por um ajuste polinomial não linear, na tentativa de prever a tendência no tempo do reservatório.

Um outro trabalho já em andamento visa incorporar técnicas de inferência estatística Bayesiana para previsão inteligente de sequências sísmicas em sinais AVO, obtidas a partir de reservatórios de hidrocarbonetos.

### Agradecimentos

Os autores agradecem à CAPES e ao CNPq pela concessão das bolsas de pesquisa e pelo apoio financeiro para realização da mesma.

### References

- Curbelo, F. D. S. (2006). *Recuperação avançada de petróleo utilizando tensoativos*. PhD thesis, Universidade Federal do Rio Grande do Norte (UFRN), Departamento de Engenharia Química.
- Fomel, S. and Long, J. (2007). Time-lapse image registration using the local similarity attribute. *77th Annual International Meeting, SEG, Expanded Abstracts*, pages 2979–2983.
- Kim, H. Y. (2011). Proeikon - rotinas e programas em c++ para processamento de imagens e visão computacional. Disponível em: <<http://www.lps.usp.br/hae/software>>. Acesso em 14 de Fevereiro de 2011.
- Lumley, D. E. (1995). 4-d seismic monitoring of an active steamflood. *65th Ann. Internat. Mtg, Soc. of Expl. Geophys.*, pages 203–206.
- Lumley, D. E. (2010). 4d seismic monitoring of co2 sequestration. *The Leading Edge*, 29(2):150–155.
- Nur, A. (1989). Four-dimensional seismology and (true) direct detection of hydrocarbons: the petrophysical basis. *The Leading Edge*, 8(9):30–36.
- Ostrander, W. J. (1984). Plane-wave reflection coefficients for gas sand at non normal angles of incidence. *Geophysics*, 49:1637–1648.
- Risso, V. F. and Schiozer, D. J. (2008). Utilização de sísmica 4d e de mapas de saturação no ajuste de histórico de reservatórios petrolíferos. *Revista Brasileira de Geociências*, 38(1):172–187.
- Rodrigues, E. P. (2010). *Avaliação de métricas para o corregristo não rígido de imagens médicas*. PhD thesis, Universidade de São Paulo (USP).
- Wiener, N. (1964). Extrapolation, interpolation, and smoothing of stationary time series. *The MIT Press*.