

6º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Predição Não-Linear de Curvas de Produção de Petróleo Via Redes Neurais Recursivas

AUTORES:

Aldayr Dantas de Araújo Júnior; Adrião Duarte Dória Neto; Wilson da Mata; Jorge Dantas de Melo.

INSTITUIÇÃO:

Universidade Federal do Rio Grande do Norte - UFRN

Este Trabalho foi preparado para apresentação no 6º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás- 6º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás-ABPG, no período de 09 a 13 de outubro de 2011, em Florianópolis-SC. Esse Trabalho foi selecionado pelo Comitê Científico do evento para apresentação, seguindo as informações contidas no documento submetido pelo(s) autor(es). O conteúdo do Trabalho, como apresentado, não foi revisado pela ABPG. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões da Associação Brasileira de P&D em Petróleo e Gás. O(s) autor(es) tem conhecimento e aprovação de que este Trabalho seja publicado nos Anais do 6ºPDPETRO.

PREDIÇÃO NÃO-LINEAR DE CURVAS DE PRODUÇÃO DE PETRÓLEO VIA REDES NEURAIS RECURSIVAS

Abstract

One of the main activities in the petroleum engineering is to estimate the oil production in the existing oil reserves. The calculation of these reserves is crucial to determine the economical feasibility of your exploitation. Currently, the petroleum industry is facing problems to analyze production due to the exponentially increasing amount of data provided by the production facilities. Conventional reservoir modeling techniques like numerical reservoir simulation and visualization were well developed and are available. This work proposes intelligent methods, like artificial neural networks, to predict the oil production and compare the results with the ones obtained by the numerical simulation, method quite a lot used in the practice to realization of the oil production prediction behavior. The artificial neural networks will be used due your learning, adaptation and interpolation capabilities.

Introdução

A engenharia de reservatórios tem apresentado um grande crescimento em temas relacionados à utilização de poços inteligentes. Esse tipo de poço possui um conjunto de equipamentos de instrumentação (sensores, válvulas e dispositivos de controle de fluxo, etc.) instalados ao longo de sua tubulação de produção. Esses equipamentos medem as variáveis de operação do poço (temperatura, pressão, abertura de válvula, etc.), alimentam bancos de dados e são usadas para monitorar, em tempo real, todas as operações do poço.

Essa grande quantidade de dados gerada permite a implementação de estratégias para melhorar a operação dos poços, ter uma noção completa do que está acontecendo quando intervenções são feitas e, principalmente, prever o que se pode acontecer no futuro.

O problema se torna ainda mais complexo quando se estende o conceito de poços inteligentes para campos inteligentes, onde o campo é visto como um sistema de poços injetores e produtores integrados, já que olhar o sistema de forma abrangente aumenta o número de fontes de geração de dados, e o número de aspectos inter-relacionados.

Essa grande quantidade de dados gera um desafio, como também uma oportunidade ímpar na tecnologia de reservatórios. O desafio é pensar como se pode modelar esse tipo de problema adequadamente. Normalmente, para eventos como esse, em que uma sequência de dados é acompanhada ao longo do tempo, métodos de séries temporais têm sido usados, com êxito, nas mais variadas áreas (Medicina, Economia, Engenharia, Meteorologia, etc.), porém ainda têm sido usadas de forma incipiente na tecnologia de reservatórios.

As redes neurais artificiais se inserem como uma importante técnica de problemas de série temporais e será utilizada como a principal ferramenta deste trabalho.

O objetivo deste é a validação de modelos preditivos para a obtenção das características de reservatórios de petróleo a partir de dados simulados, utilizando as redes neurais artificiais como técnica para a predição de produção de petróleo. As RNA (Redes Neurais Artificiais) serão utilizadas por possuírem boas características no que se refere à classificação de padrões e de reconhecimento de padrões, além da sua capacidade de aproximação de funções e interpolação, tornando-as ideais para realizar tarefas de predição.

A finalidade deste trabalho não é substituir as ferramentas e métodos clássicos de estimar características dos reservatórios. A pretensão fica por conta de se buscar novas técnicas que podem apresentar vantagens em situações que os métodos clássicos (em especial a simulação) consumam mais tempo e recursos computacionais. Outro ponto importante é a oportunidade de se usar dados que agora estão disponíveis com a implantação de poços inteligentes.

Metodologia

Para efetuar o estudo proposto, algumas ferramentas computacionais são necessárias. Tanto aquelas relacionadas à simulação de reservatórios quanto à inteligência computacional.

O processo foi realizado através do simulador comercial STARS (Steam, Thermal, and Advanced Processes Reservoir Simulator) – versão 2007, um simulador numérico trifásico de múltiplos componentes da CMG (Computer Modelling Group).

O STARS é o simulador térmico e de processos avançados de reservatório mais utilizado pela indústria. Suas robustas reações cinéticas e capacidades geo-mecânicas fazem-no o mais completo e flexível simulador de reservatório disponível para modelar o complexo processo de recuperação de óleo e gás que estão sendo estudados e implementados atualmente. Além de poder ser utilizado em vários sistemas operacionais.

Para as redes neurais a ferramenta computacional utilizada para se fazer as implementações necessárias foi o software Matlab. Este possui uma grande facilidade de operar com matrizes e vetores, além de possuir uma linguagem interpretada bastante intuitiva. Além disso, possui vários *toolboxes* para diferentes aplicações, entre elas para otimização, redes neurais e cálculos financeiros.

O modelo físico adotado consiste em um modelo retangular tridimensional de malha cartesiana. A Figura 1 apresenta o reservatório em 3D, mostrando o refinamento utilizado e as dimensões do reservatório.




Figura 1: Modelo Base

Considera-se que não existe fluxo de fluidos através dos limites do reservatório e são feitas as seguintes considerações: só existem as fases água e óleo, a fase óleo é composta só por óleo, não existem reações químicas, não existem sólidos nos fluidos a serem considerados, não existe perda de calor para as partes adjacentes do reservatório.

O reservatório estudado apresenta uma zona de água de 6 m. As características adotadas na simulação foram:

- Injeção em malha: ¼ five spot,
- Número de blocos: 9200 blocos;
- Comprimento=largura: 20 blocos de 5,0 m cada;
- Espessura: 20 camadas de 1 m; 3 camadas de 2 m

Com relação aos parâmetros analisados foi verificada a sensibilidade de alguns parâmetros operacionais (vazão de injeção de fluidos, qualidade do vapor, ou título de vapor, e intervalo de completação) sobre a produção acumulada de óleo e a vazão de produção de petróleo.

Para analisar as respostas de interesse com base nas diferentes interações entre os parâmetros escolhidos, foi realizado um planejamento fatorial de três níveis: mínimos (-1), intermediários (0) e máximos (+1).

Desta maneira, para cada parâmetro analisado, foram obtidas 3 diferentes situações para se fazer as simulações necessárias. Estes parâmetros do reservatório foram utilizados para treinar a rede neural em 27 cenários diversos.

A Tabela 1 apresenta os parâmetros analisados com seus respectivos níveis.

Parâmetro	Valor Mínimo (-1)	Valor Intermediário (0)	Valor Máximo (+1)
Vazão de Injeção- t/dia	25	37,5	50
Título do Vapor (%)	50	70	90
Intervalo de Completação	Base	Centro	Topo

Tabela 1: Níveis dos parâmetros operacionais analisados

Este trabalho propõe um mecanismo capaz de reproduzir o comportamento do simulador utilizando apenas o conjunto de saídas, em uma abordagem de predição. O algoritmo de predição é baseado em uma rede neural recorrente do modelo NARX (Menezes, 2006). Esta rede possui uma arquitetura neural recorrente usada originalmente para identificação entrada-saída de sistemas não-lineares. Quando aplicada para predição de séries temporais, a rede NARX é projetada geralmente como um modelo autoregressivo não-linear (NAR). A Figura 2 ilustra o problema de predição estudado.

O algoritmo de predição proposto recebe como entrada os dados da simulação (as curvas de produção acumulada e de vazão) fornecidos pelo simulador e fornece como saída uma estimativa do valor no tempo $n+h$ onde h representa o horizonte de predição. Se $h = 1$, tem-se predição de passos simples, enquanto $h > 1$ corresponde à predição de passos múltiplos. A arquitetura recorrente em estudo neste trabalho deve ser capaz de prover estimativas confiáveis, tanto para um horizonte de predição de passos simples quanto para um horizonte de múltiplos passos.

A Figura 2 ilustra como é realizado o processo de treinamento da arquitetura selecionada. A saída da rede será comparada com o valor do sinal desejado $y(n+h)$ proveniente do simulador. O erro de predição é calculado e, então, os pesos da rede são atualizados, utilizando o algoritmo de Levenberg-Marquardt.

No passo seguinte, um novo conjunto de treinamento é apresentado à entrada da rede. A resposta da mesma é realimentada para o regressor de saída, e a próxima resposta obtida, $\hat{y}(n+h)$, será comparada ao valor do sinal no instante de tempo subsequente em que o erro é calculado e utilizado para atualizar os pesos sinápticos novamente. Este processo se repete até que um número pré-definido de passos seja alcançado.

Após o processo de aprendizado, o objetivo é determinar um limite de confiabilidade para as estimativas realizadas pela rede neural, ou seja, deve-se garantir que o erro entre a saída do simulador e a saída da rede neural permaneça dentro de um limite aceitável.

A análise do erro de predição, que corresponde à diferença entre o valor do simulador e o valor esperado, obtido através da predição, é utilizada para determinar se a predição para uma dada situação é viável ou não.




Figura 2: Preditor Construído a Partir de uma Rede Neural

Resultados e Discussão

Uma ferramenta vastamente usada para previsão do comportamento de curvas de produção é o simulador numérico. O objetivo deste estudo é avaliar o uso de RNAs como técnica para a previsão de produção e comparar seus resultados com os obtidos pelo simulador numérico. Com este intuito, alguns casos sintéticos foram construídos e computados no simulador para servir de referência nas comparações dos resultados.

Este estudo de casos tem a intenção de contemplar duas situações distintas. Na primeira, os valores da vazão de injeção de vapor, do título de vapor e do intervalo de completação não variam. Na segunda situação, o valor da vazão de injeção de vapor varia para metade no momento em que o reservatório atinge o valor máximo de vazão (produção), permanecendo constantes os valores do título

de vapor e do intervalo de completação. Esta alteração no valor da vazão de injeção foi feita para verificar se o aprendizado da rede neural sofria alguma modificação com um parâmetro variável.

Além disso, foram feitas simulações envolvendo um regressor de saída contendo uma memória de linha de atraso tanto de ordem 2 como de ordem 10, como citado anteriormente. Essas simulações têm o objetivo de comparar os resultados obtidos de modelos com memórias de linha de atraso de ordem diferentes.

Nas simulações que envolviam a memória de linha de atraso de ordem 2, a entrada da rede neural consistia dos valores da vazão de injeção de vapor, título de vapor, intervalo de completação e de duas saídas atrasadas no tempo realimentadas do simulador, para que a rede neural gerasse o passo seguinte de predição.

Já para o caso que contempla a memória de linha de atraso de ordem 10, a entrada da rede neural consistia dos valores da vazão de injeção de vapor, título de vapor, intervalo de completação e de dez saídas atrasadas no tempo realimentadas do simulador, para que a rede neural gerasse, desta maneira, o passo seguinte de predição.

A grande vantagem observada da utilização das redes neurais nas simulações, foi o tempo de processamento das informações. Enquanto que no simulador as simulações duravam um tempo de aproximadamente duas horas e meia, com as redes neurais o tempo gasto ficou em torno de 10 segundos.

Conclusões

Este trabalho teve como objetivo estudar um método de técnicas inteligentes, as redes neurais, junto com ferramentas da engenharia de reservatórios para tentar produzir soluções mais eficientes na predição de produção de petróleo.

Foi implementado um preditor, baseado em uma rede neural recorrente, utilizado para reproduzir as saídas do simulador. Os resultados obtidos demonstraram a capacidade preditiva do algoritmo e se mostraram satisfatórias, tanto na situação em que os parâmetros de entrada (vazão de injeção, título de vapor e intervalo de completação) são constantes quanto na situação em que o valor da vazão de injeção é alterada para a metade ao longo de sua dinâmica, sendo esta última situação com um melhor desempenho de predição em relação à primeira.

Com a predição de passo simples pode-se concluir que o preditor neural tem capacidade de reproduzir o comportamento do simulador ao longo do tempo.

As situações testadas se mostraram eficientes na modelagem do problema, permitindo bons resultados de previsão de produção. A utilização de uma memória de linha de atraso de ordem 2 forneceu resultados similares aos obtidos com memória de linha de atraso de ordem 10, sugerindo que a memória de linha de atraso de ordem 2 já se constitui em uma boa aproximação para este problema.

Este bom resultado pode sugerir o uso de redes neurais como uma ferramenta adicional às já atualmente utilizadas curvas de declínio e simulação numérica ou ainda em situações que essas ferramentas são de difícil utilização.

Agradecimentos

Aos professores Adrião Duarte e Wilson da Mata pela confiança depositada em mim e por compartilharem seus conhecimentos e experiências essenciais para a realização deste trabalho.

Referências Bibliográficas

- ALMEIDA, L. F. et al., *Evolutionary Optimization of Smart-Wells Control Under Technical Uncertainties*. Society of Petroleum Engineers – 107872. Buenos Aires, Argentina, 2007.
- BARBOSA, A. H.; FREITAS, M. S. R.; NEVES, F. A. Confiabilidade Estrutural Utilizando o Método de Monte Carlo e Redes Neurais. *Rev. Esc. Minas*, vol.58, n. 3, pp. 247-255, 2005.
- CMG, Computer Modelling Group Ltda. Guia para el usuario. Steam, Thermal and Advanced Reservoir Simulator – STARS. Versão 2007.11, Calgary-Alberta-Canadá.
- EMERICK, A. A.; PORTELLA, R.C.M., *Production Optimization With Intelligent Wells*. Society of Petroleum Engineers – 107261. Buenos Aires, Argentina, 2007.
- GOMES, D.T. *Redes Neurais Recorrentes para Previsão de Séries Temporais de Memórias Curta e Longa*. Dissertação (Mestrado), Universidade Estadual de Campinas, Campinas, SP, 2005.
- HAGAN, M. T.; MENHAJ, M. B. Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, vol. 5, n.5, pp. 989-993, 1994.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*, 2. ed. Porto Alegre: Bookman, 2001.
- HOLLAND, J. et al., *Utilizing the Value of Continuously Measured Data*. Society of Petroleum Engineers – 90404. Houston, USA, 2004.
- JOHNSTONE, S. et al., *Implementing Intelligent Well Completion in Brown Field Development*. Society of Petroleum Engineers – 77657. San Antonio, USA, 2002.
- KROME, J.; MATSON, J., *Proper Project Selection of Real-Time Management Approaches*. Society of Petroleum Engineers – 106927. Houston, USA, 2007.
- LOURAKIS, M. *A Brief Description of the Levenberg-Marquardt Algorithm*. Institute of Computer Science. Crete, Greece, 2005.
- MEDEIROS, J.P. de. *Estudo e Implementação de Algoritmos Inteligentes para Detecção e Classificação de Falhas na Medição de Gás Natural*. Dissertação (Mestrado em Ciência e Engenharia de Petróleo) – Centro de Tecnologia, Programa de Pós-Graduação em Ciência e Engenharia de Petróleo, Universidade Federal do Rio Grande do Norte, Natal, 2009.
- MENEZES, J. M. P. *Redes Neurais Dinâmicas para Predição e Modelagem Não-Linear de Séries Temporais*. Dissertação (Mestrado em Engenharia de Teleinformática) – Programa de Pós-Graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2006.
- MEUM, P. et al., *Optimization of Smart Well Production Through Nonlinear Model Predictive Control*. Society of Petroleum Engineers 112100. Amsterdam, The Netherlands, 2008.
- MUELLER, A. *Uma Aplicação de Redes Neurais Artificiais na Previsão do Mercado Acionário*. Dissertação (Mestrado), Universidade Federal de Santa Catarina, Florianópolis, 1996.
- PAINO, W. et al., *Using Intelligent Well Technology to Define Reservoir Characterization and Reduce Uncertainty*. Society of Petroleum Engineers 88533. Perth, Australia, 2004.
- PANDA, M. N.; CHOPRA, A. K. *An Integrated Approach to Estimate Well Interactions*. Society of Petroleum Engineers 39563. Nova Deli, India, 1998.

6º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS

- PRINCIPE, J.C.; KUO. J. Dynamic Modelling of Chaotic Time Series with Neural Networks. *Advances in Neural Information Processing Systems* 7, p. 311-318, 1995.
- ROSA, A. J.; CARVALHO, R. de S.; XAVIER, J. A. D. *Engenharia de reservatórios de petróleo*, 1. ed., Rio de Janeiro: Interciência, 2006.
- SILVA Jr, M. F.; PORTELLA, R.C.M.; IZETTI, R.G.; CAMPOS, S.R.V., *Technologies Trials of Intelligent Field Implementation in Carmopolis Field*. Society of Petroleum Engineers 95517. Dallas, USA, 2005.
- SILVA, L. C. F. da. *Inteligência Computacional para Predição de Produção de Reservatórios de Petróleo*. Tese (Doutorado em Engenharia Civil) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.
- SOARES, P. P. S.; N, JURANDIR. Aplicação de uma Rede Neural *Feedforward* com Algoritmo de Levenberg - Marquardt para Classificação de Alterações do Segmento ST do. Eletrocardiograma. In: IV CONGRESSO BRASILEIRO DE REDES NEURAI, 07, 1999, São José dos Campos. pp. 384-389.
- STUNDNER, M.; AL-THUWAINI, J. S., *How Data-Driven Modeling Methods Like Neural Networks Can Help to Integrate Different Types of Data into Reservoir Management*. Society of Petroleum Engineers 68163. Bahrain, 2001.
- THOMAS, J.E. et al. *Fundamentos de Engenharia de Petróleo*, 2ª ed. Rio de Janeiro: Interciência , 2001.
- WEISS, W. W.; BALCH, R. S.; STUBBS, B. A., *How Artificial Intelligence Methods Can Forecast Oil Production*. Society of Petroleum Engineers 75143. Tulsa, USA, 2002.
- YETEN, B.; DURLOFSKY, L. J.; AZIZ, K., *Optimization of Smart Well Control*. Society of Petroleum Engineers 79031. Calgary, Canada, 2002.