

5º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Aplicação de Redes Neurais Artificiais como Metamodelos ao Ajuste de Histórico

AUTORES:

Tiago Pitchon Sampaio
Virgílio José Martins Ferreira Filho
Abelardo de Sá Neto

INSTITUIÇÃO:

Universidade Federal do Rio de Janeiro

Este Trabalho foi preparado para apresentação no 5º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás- 5º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás-ABPG, no período de 15 a 22 de outubro de 2009, em Fortaleza-CE. 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 5ºPDPETRO.

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS COMO METAMODELOS AO AJUSTE DE HISTÓRICO

Abstract

Reservoir simulation is an important tool used in the industry for reservoir management. While developing a field, a reservoir simulation model is used as a decision tool to select the best development scheme and also to forecast the oil, gas and water production for the field. Uncertainties are much higher at the early phases and when production data are gathered during the field development phase most of the time the initial reservoir simulation model needs to be reviewed once the field observed data is not as the same as the predicted by the model. Some of these uncertainties of input parameters of the model simulation of reservoirs are related to the heterogeneities of the reservoir rock and imprecision of the techniques of exploitation.

History matching techniques are used by reservoir engineers to mitigate/minimize the difference about the observed field data and the predicted and thus assessing the uncertainties. When reservoir models become too big in terms of number of cells and features, the elapsed simulation time increases very much what it makes the history matching process very cumbersome and in some cases very difficult to achieve in an acceptable time. Parallel processing features of some commercial simulators can perform lots of simulation runs at the same time but cannot address and cannot solve the problem in a proper way.

This work presents an alternative proposition to speed up the history matching process: the application of feed-forward neural networks as nonlinear proxies of reservoir simulation. Neural networks can map the response surface in multidimensional spaces of a reservoir model (i.e. water production, bottom hole pressure etc.) or of an objective function with few number of simulations and then used it as a substitute of reservoir simulation runs during the history matching process. The focus of this work is to shown the steps of choosing the best number of hidden layers, the neurons and the training method. An study case is presented using the workflow presented is this work and showing the validity of the proposed methodology for this nonlinear problem.

Introdução

Simulação de Reservatórios é uma importante ferramenta usada pela indústria no gerenciamento de reservatórios. Durante o desenvolvimento de um campo, o modelo de simulação de reservatórios é usado como ferramenta de decisão para selecionar o melhor esquema de produção e, também, prever as produções esperadas de óleo, água e gás para este campo. As incertezas são elevadas nas fases iniciais e, quando os dados de produção são adquiridos durante a fase de desenvolvimento do campo, na maior parte das vezes, o modelo inicial de simulação necessita ser revisto, visto que os dados observados no campo não são os mesmos daqueles previstos pelo modelo. Algumas dessas incertezas dos parâmetros de entrada do modelo estão relacionadas a heterogeneidades da rocha reservatório.

Técnicas de ajuste de histórico são utilizadas pelos engenheiros de reservatório para minimizar/mitigar as diferenças entre os dados observados no campo e aqueles previstos pelo modelo e tratar as incertezas. Quando o modelo de reservatório se torna muito grande em função do número de células e detalhes, o tempo total de simulação aumenta exponencialmente, tornando o ajuste de histórico complicado e, muitas vezes, difícil de ser executado em um tempo viável. Mohaghegh (2006) apresentou um caso de simulação de um campo com 165 poços e 1 milhão de blocos no qual o tempo total de processamento era cerca de 10 horas em um *cluster* com 12 processadores 3,2 GHz.

Redes neurais artificiais têm sido apresentadas como uma importante ferramenta na solução deste problema por Cullick *et al.* (2006) and Silva *et al.* (2006). Alguns tipos de redes neurais, como as redes de alimentação-direta (*feed-forward*), podem mapear a superfície de resposta multidimensional de um modelo de reservatório (exemplo: produção de água, pressão no fundo do poço,...) ou a função objetivo utilizando apenas algumas simulações. A resposta mapeada é usada, então, para substituir a simulação de reservatórios durante o processo de ajuste de histórico. Apesar das altas perspectivas acerca das redes neurais, uma boa ferramenta para o estudo de simulações, sua implementação e utilização não são simples. Elas são dependentes da experiência dos usuários que deve responder a perguntas relacionadas aos processos de criação e treinamento da rede neural, como:

- Que tipo de rede neural usar?
- Quantas camadas ocultas? Caso seja selecionada uma rede do tipo alimentação direta.
- Quantos neurônios devem ser usados nas camadas de entrada, escondida e de saída?
- Quais são os parâmetros de entrada e de saída da rede neural?
- Quantos modelos de simulação são necessários para treinar adequadamente uma rede neural artificial?
- Como selecionar as respostas dos modelos de simulação?
- Que algoritmo de treinamento deve ser utilizado?
- A rede neural artificial é boa o suficiente para executar a tarefa?

Redes Neurais Artificiais

Redes neurais artificiais fazem parte de um conjunto de ferramentas analíticas criadas com o objetivo de imitar a vida (Mohaghegh, 2000). Neste caso, são algoritmos inspirados na mecânica do cérebro animal e que, embora sejam bastante simples, possuem a capacidade de executar uma série de tarefas como aproximar funções, controle, reconhecimento de padrões, filtragem não linear e outros.

O objetivo deste tópico é apresentar as redes neurais do tipo alimentação-direta (*feed-forward*). Este é o tipo mais comum de rede neural e é utilizado em uma grande variedade de problemas. Informações detalhadas sobre redes neurais artificiais, incluindo outros tipos e aplicações, pode ser encontradas em Mohaghegh (2000), Kröse and Smagt (1996), and Demuth et al. (2008).

A figura 1 apresenta o desenho esquemático de um neurônio artificial. Este neurônio tem como entrada o vetor $[x_1, x_2, \dots, x_n]$ e, como saída, a variável Y . O vetor de entrada é multiplicado pelo vetor de pesos $[w_1, w_2, \dots, w_n]$ e somado ao peso independente b , resultando na variável u . A esta variável é aplicada a função de ativação, $f(u)$, gerando a variável de saída Y de dimensão 1.




Figura 1: Esquema de um neurônio.

Os neurônios são agrupados em camadas formando redes neurais. A figura 2 ilustra as redes do tipo alimentação-direta. Nela, podem-se observar os seguintes tipos de camadas:




Figura 2: Exemplo de rede neural tipo alimentação-direta.

- Camada de entrada: é a camada com neurônios na cor azul, marcados pela letra “E”. Nela, cada neurônio só pode receber um valor do vetor de entrada e não possui função de ativação, ou seja, o valor do vetor de entrada passa direto para camada seguinte onde será multiplicado pelos pesos. O número de neurônios desta camada é igual à dimensão do vetor de entrada, havendo um neurônio para cada variável de entrada.
- Camada escondida (ou intermediária ou oculta): é a camada com neurônios na cor verde, marcados pela letra “O”. Nela, os neurônios recebem as saídas da camada anterior multiplicados pelos seus pesos e somados ao peso independente. A função de ativação e o número de neurônios desta camada são definidos pelo programador conforme a necessidade, sendo, neste trabalho, a função sigmóide. Pode haver mais do que uma camada deste tipo na rede.
- Camada de saída: é a camada com neurônios na cor vermelha da figura, marcados pela letra “S”. Nesta camada, os neurônios recebem as saídas da última camada escondida e sua função de ativação é, geralmente, linear. O número de neurônios desta camada é igual à dimensão do vetor de saída, havendo um neurônio para cada variável de saída.

O objetivo do treinamento da rede neural artificial é definir os pesos de forma que ele possa fornecer uma resposta similar a do simulador de reservatórios. O tempo decorrido para obter uma resposta de redes neurais é insignificante quando comparado ao tempo de simulação de reservatório. Isso torna o processo iterativo de ajuste de histórico para um reservatório complexo viável.

O método mais comum de treinamento de redes neurais do tipo alimentação-direta é a retro-propagação (*back-propagation*). Neste método, os pesos são inicialmente fixados aleatoriamente. Um grupo de pares de entrada-saída obtidos a partir de modelos de simulação reservatório, chamado pares de treinamento, é selecionado. Os valores de saída dos pares de treinamento são comparados com a saída da rede neural artificial e o erro, que representa a "função desempenho" do método de treinamento, é calculado. Neste trabalho, foi utilizado o erro médio quadrático. Os pesos são ajustados a partir da camada de saída para a camada de entrada iterativamente até que a “função desempenho” torna-se suficientemente pequena. O sucesso no treinamento das redes neurais artificiais depende do quão bem os pares de treinamento são selecionados. Eles devem representar a multidimensionalidade da superfície/curva de resposta definida pela simulação de reservatório visto que é um problema de aproximação.

O teorema da aproximação universal define que, para uma rede neural do tipo alimentação-direta e treinamento retro-propagação, "apenas uma camada escondida de unidades é suficiente para aproximar

qualquer função com número finito de descontinuidades com uma precisão arbitrária, desde que as funções de ativação da camada escondida sejam não-lineares" (tradução de Kröse e Smagt, 1996). Este teorema serve de suporte para a utilização de uma rede neural tipo alimentação-direta com uma camada escondida utilizados neste trabalho.

O Modelo de Simulação de Reservatórios e Método de Ajuste de Histórico

O estudo de caso deste trabalho foi inspirado no modelo apresentado por Ertekin *et al.* (2001). Um modelo heterogêneo (ver figura 3) representa o reservatório real e fornece os dados observados. Um modelo homogêneo serve como modelo simulado a ser ajustado. Há 3 poços produtores: Well-001, Well-003 e Well-005, e 2 injetores: Well-002-I e Well-004-I. O reservatório é, inicialmente, apenas saturado em óleo.




Figura 3: Distribuição de porosidade do modelo heterogêneo.

Quatro parâmetros do reservatório foram ajustados (parâmetros de entrada): porosidade, permeabilidade na direção “x”, na direção “y” e compressibilidade da rocha. O erro médio quadrático da vazão de água produzida no poço Well-005 para os dois primeiros anos é a função objetiva utilizada no processo de ajuste de histórico. O método utilizado é baseado na busca direta de Maschio e Schiozer (2005).

Definindo e Treinando a Rede Neural Artificial

Baseado no que foi apresentado nos tópicos anteriores, a rede neural selecionada é do tipo alimentação-direta treinada pelo método retro-alimentação. O algoritmo de treinamento escolhido é o Levenberg-Marquardt que apresentou bons resultados nos testes.

Esta rede neural possui apenas 1 camada escondida com 10 neurônios, sendo este número também definido em testes, 5 neurônios na camada de entrada (um para cada parâmetro a ser ajustado e outro para o tempo) e 1 neurônio para a camada de saída (produção de água no poço 5 no tempo t).

Cada parâmetro de entrada foi definido como uma variável aleatória uniformemente distribuída em um intervalo conhecido. Com isso, geraram-se diversos modelos de simulação para o treinamento da rede, sendo observado que 50 modelos eram suficientes para treinar uma boa rede. A figura 4 mostra uma

comparação entre a saída do simulador de reservatórios e da rede neural artificial para um dos modelos usados:




Figura 4: Comparação entre a resposta do simulador e da rede neural para um dos modelos de reservatório utilizados no treinamento.

Realizando o Ajuste de Histórico

Com a rede neural artificial definida e treinada, está na hora de realizar o processo ajuste de histórico. A metodologia utilizada foi baseada na busca direta de Maschio e Schiozer (2005). Nela, os intervalos dos parâmetros a serem ajustados são discretizados, facilitando processo de busca pela região de menor valor da função objetivo. Esta é definida como o erro médio quadrático da vazão de água produzida do poço Well-005 nos dois primeiros anos de produção.

Nesta metodologia, um ponto aleatório, ou modelo de reservatório inicial, é selecionado para iniciar o ajuste de histórico e a sua função objetivo é calculada. Então, as funções objetivo dos pontos vizinhos são calculadas. Aquele que possuir o menor valor define a direção da busca, ou seja, a propriedade que seja ajustada nesta iteração. A busca continua nesta direção/propriedade até que o valor da função objetivo atinja um mínimo. O último ponto investigado nesta iteração passa ser o ponto de partida iteração seguinte e o processo é repetido até chegar a um mínimo. Para evitar mínimos locais, 10 modelos de reservatório foram selecionados como pontos de partida.

As figuras 5 e 6 apresentam o resultado do ajuste de histórico. Observa-se que o simulador e a rede neural forneceram respostas similares antes e após o ajuste.




Figura 5: Comparação da resposta da rede neural artificial (RN) com a produção observada antes do ajuste.




Figura 6: Comparação da resposta da rede neural artificial (RN) com a produção observada após o ajuste de histórico.

Para realizar este ajuste de histórico com os 10 pontos selecionados, seriam necessárias aproximadamente 900 simulações de reservatório, cálculo teórico. Utilizando a rede neural como metamodelo foram rodadas apenas 50 simulações.

Conclusões

A metodologia proposta neste trabalho foi aplicada com sucesso no caso estudado. Reduziu-se sensivelmente o número de simulações necessárias para o ajuste de histórico economizando tempo e processamento sem haver perdas consideráveis na qualidade do ajuste.

Os três pontos abaixo apresentam experiências adquiridas ao longo do trabalho e merecem ser ressaltadas:

- A rede neural é utilizada, nesta metodologia, para interpolar funções. Ela não serve para prever a produção para tempos além daqueles usados no treinamento.

- Uma rede neural só pode ser utilizada para ajustar o reservatório para o qual foi treinada e, se o modelo variar drasticamente, um novo treinamento deve ser realizado.
- Ainda não é possível obter uma fórmula para determinar o número ótimo de neurônios na camada escondida e de simulações. A experiência e sentimento do programador são as melhores armas no momento.

O sucesso na aplicação da rede neural como um interpolador da superfície de resposta do simulador de reservatórios, dado um modelo, para o ajuste de histórico demonstra o grande potencial que esta ferramenta ainda tem para a indústria do petróleo.

Agradecimentos

À Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – ANP, e à Financiadora de Estudos e Projetos – FINEP que, através do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás Natural – PRH-ANP/MME/MCT número 21, forneceram o apoio financeiro fundamental ao desenvolvimento deste trabalho.

Referências Bibliográficas

CULLICK, A. S.; JOHNSON, D.; SHI, G. Improved and More-Rapid History Matching With a Nonlinear Proxy and Global Optimization. *SPE Annual Technical Conference and Exhibition*. San Antonio, Texas: Society of Petroleum Engineers, 2006.

DEMUTH, H.; BEALE, M.; HAGAN, M. *Neural Network Toolbox™ 6 User's Guide*. The MathWorks, 2008. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 3 de dezembro de 2008.

ERTEKIN, T.; ABOU-KASSEM, J. H.; KING, G. R. *Basic Applied Reservoir Simulation*. 1. ed. Richardson, Texas: Society of Petroleum Engineers, 2001. (Textbook, 7).

KRÖSE, B.; SMAGT, P. V. D. *An Introduction to Neural Networks*. University of Amsterdam, 1996. Disponível em: <www.avaye.com/files/articles/nnintro/nn_intro.pdf>. Acesso em: 11 de dezembro de 2008.

MASCHIO, C.; SCHIOZER, D. J. Comparação entre Metodologia de Otimização Global e o Método de Gradientes para Ajuste de Histórico Assistido. *3º Congresso Brasileiro de P&D em Petróleo e Gás*. Salvador, Bahia: Associação Brasileira de Pesquisa e Desenvolvimento em Petróleo e Gás, 2005.

MOHAGHEGH, S. Virtual-Intelligence Applications in Petroleum Engineering: Part 1—Artificial Neural Networks. *Journal of Petroleum Technology* [S.I.], v. 52, n. 9, p. 8, setembro 2000.

MOHAGHEGH, S. D. Quantifying Uncertainties Associated With Reservoir Simulation Studies Using Surrogate Reservoir Models. *2006 SPE Annual Technical Conference and Exhibition*. San Antonio, EUA: Society of Petroleum Engineers, 2006.

SILVA, P. C.; MASCHIO, C.; SCHIOZER, D. J. Evaluation of Neuro-Simulation Techniques as Proxies to Reservoir Simulator. *Rio Oil & Gas Expo and Conference 2006*. Rio de Janeiro, Brasil: Instituto Brasileiro de Petróleo, Gás e Biocombustíveis, 2006.