

PREDIÇÃO NÃO-LINEAR DE CURVAS DE PRODUÇÃO DE PETRÓLEO VIA REDES NEURAS RECORRENTES

Aldayr Dantas de Araújo Júnior¹, Adrião Duarte Dória Neto², Wilson da Mata² e Jorge Dantas de Melo²

Instituto Federal do Rio Grande do Norte (IFRN)¹, Universidade Federal do Rio Grande do Norte (UFRN)²
aldayr.araujo@ifrn.edu.br; adriao@dca.ufrn.br; wilson@ct.ufrn.br; jdmelo@dca.ufrn.br

Resumo – Uma das atividades essenciais na engenharia de petróleo é a estimativa de produção de óleo existente nas reservas petrolíferas. O cálculo dessas reservas é crucial para a determinação da viabilidade econômica de sua exploração. Atualmente, a indústria do petróleo tem se deparado com problemas para analisar a produção enquanto facilidades operacionais disponibilizam um volume de informações que crescem exponencialmente. Técnicas convencionais de modelagem de reservatórios como simulação matemática e visualização estão bem desenvolvidas e disponíveis. A proposta deste trabalho é o uso de técnicas inteligentes, como as redes neurais artificiais, para a predição de produção de petróleo e comparar seus resultados com os obtidos pela simulação numérica, método bastante utilizado na prática para a realização de predição do comportamento da produção de petróleo. As redes neurais artificiais serão usadas devido a sua capacidade de aprendizado, adaptação e interpolação.

Palavras - chave – Predição, Redes neurais artificiais, Simulação numérica.

1 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 seqüência 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) consomem 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.

Atualmente, vários trabalhos envolvendo a modelagem de problemas de engenharia propõem algum tipo de utilização de redes neurais. Na área de petróleo não tem sido diferente. Weiss, W. W., Balch, R. S., Stubbs, B. A. (2002) utilizaram a classificação por lógica fuzzy para escolher as variáveis de entrada de uma rede neural em que estas podem ser treinadas, testadas e usadas para prever a produção de petróleo. Yeten, B., Durlofsky, L., Aziz, K. (2002) apresentaram um método geral para otimização de poços de petróleo com dispositivos de controle de fluxo. O método implica no uso de uma ferramenta de otimização baseada no algoritmo de gradiente conjugado. Holland, J. et al., (2004) descreveram a experiência da implantação de um sistema automático de gerenciamento de reservatórios, no campo de Medusa, Golfo do México, utilizando a ferramenta computacional Decide!, um banco de dados em tempo real offshore, um banco de dados em tempo real onshore, a integração

de banco de dados adicionais e simuladores. Silva Jr, M. et al., (2005) realizaram um estudo em que uma série de processos tecnológicos foram utilizados para automatizar por completo o campo de exploração de Carmópolis, Brasil. Este processo incluía a completção de poços inteligentes e a automação da elevação artificial com um sistema SCADA, para que uma integração sistemática das técnicas de medições, comunicação e controle do campo fosse alcançada, melhorando assim o gerenciamento da produção do reservatório. Silva, L. (2006) estudou métodos inteligentes como redes neurais e algoritmos genéticos junto com ferramentas de modelagem de reservatórios, para produzir soluções mais eficientes na predição e otimização da produção de petróleo. Emerick, A., Portella, R. (2007) descreveram uma implementação de um método para otimizar a produção em poços inteligentes variando as posições das válvulas de controle de fluxo usando um algoritmo de otimização, baseado em métodos de busca direta, acoplado em simuladores comerciais de fluxo. Em 2007, Almeida, L. et al. apresentaram um sistema, baseado em algoritmos evolutivos, capazes de otimizar o processo de controle da tecnologia de poços inteligentes. Na otimização foi considerado o risco de defeito que poderia existir nos dispositivos de controle.

2 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.

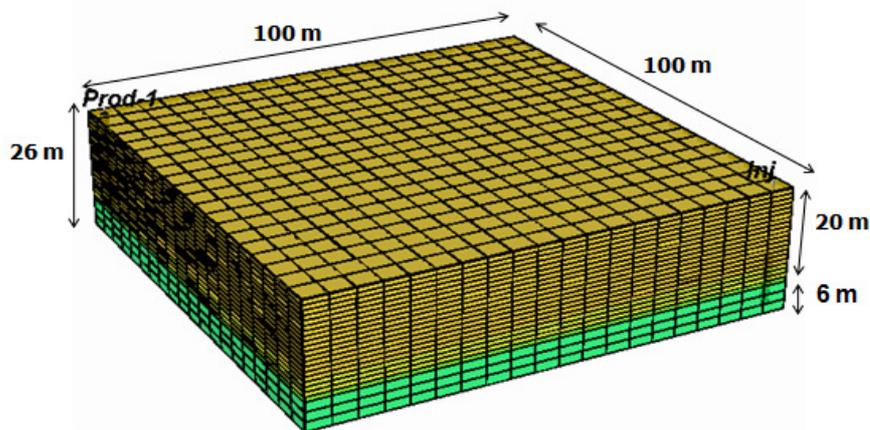


Figura 1: Modelo Base

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: $\frac{1}{4}$ 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

A nomenclatura abaixo exhibe o significado das definições para o parâmetro intervalo de completação:

- BASE – Injetar na base da zona de óleo;
- TOPO – Injetar no topo da zona de óleo;
- CENTRO - Injetar no centro da zona de óleo;

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 (Lourakis, 2005).

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.

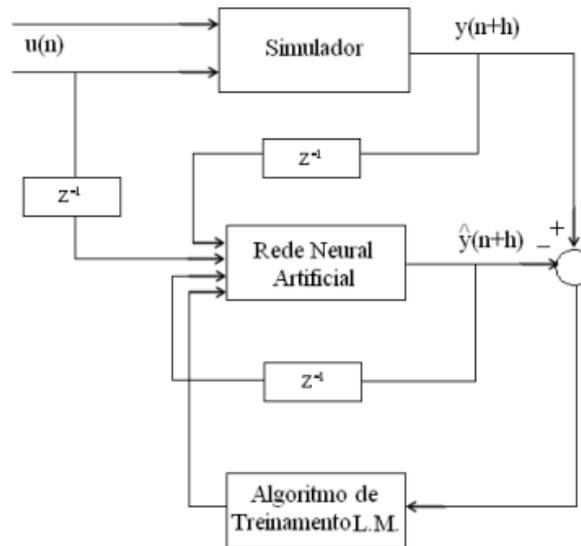


Figura 2: Preditor Construído a Partir de uma Rede Neural

3 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 a situação em que os valores da vazão de injeção de vapor, do título de vapor e do intervalo de completção não variam.

Além disso, foram feitas simulações envolvendo um regressor de saída contendo uma memória de linha de atraso de ordem 2. Nestas simulações, a entrada da rede neural consistia dos valores da vazão de injeção de vapor, título de vapor, intervalo de completção e de duas saídas atrasadas no tempo realimentadas do simulador, para que a rede neural gerasse 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.

Foi escolhido o caso a seguir, para apresentar o comportamento do preditor neural:

- Vazão de injeção: 25t/dia
- Intervalo de completção: Base
- Título de vapor: 50%

As simulações foram feitas para um período de 15 anos, com os dados (produção acumulada e vazão) sendo obtidos com intervalos mensais. O simulador gerou os dados de janeiro do ano 2000 até dezembro de 2014, totalizando 180 meses de informações. As simulações foram feitas considerando os valores dos três parâmetros (vazão de injeção de vapor, intervalo de completção e título de vapor) sendo constantes. Nas predições de passo simples foi considerado um número de passos adiante em que o erro entre o sinal do simulador e o sinal proveniente da rede poderia ter no máximo um valor de 10%. Serão mostrados os resultados obtidos para o regressor de saída com uma memória de linha de atraso de ordem 2.

A Figura 3 ilustra a curva de treinamento da rede neural com a curva do simulador para a produção acumulada de petróleo. O algoritmo de Levenberg-Marquardt, (Hagan & Menhaj, 1994), foi utilizado para o processo de aprendizado. O

o sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

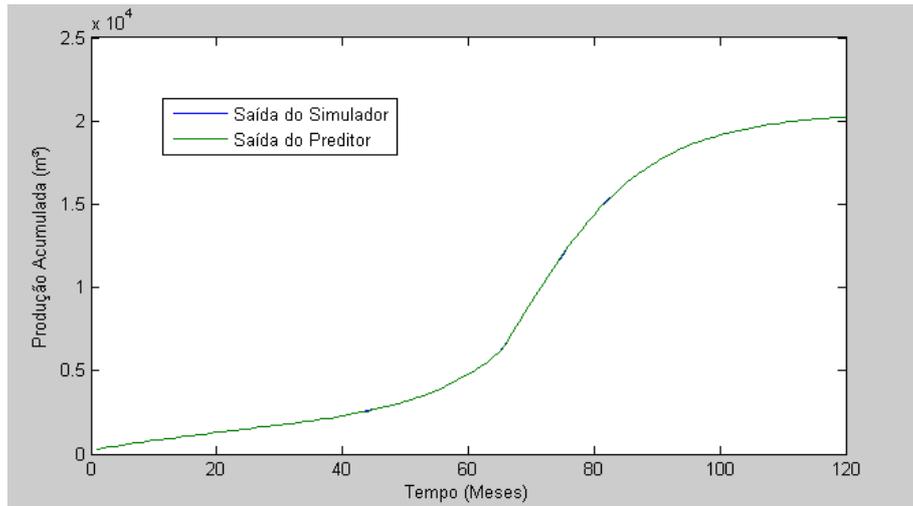


Figura 3: Treinamento para a curva de produção acumulada

Na Figura 4 é ilustrado o gráfico utilizado para analisar a previsão de passo simples com 12 passos adiante, realizada pela rede neural para a produção acumulada de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

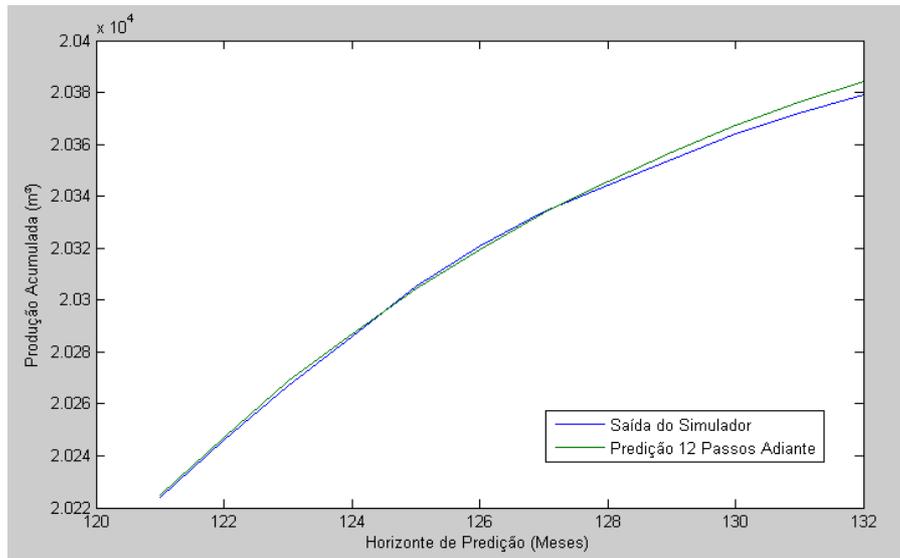


Figura 4: Sinal da produção acumulada obtido pela previsão de 12 passos

Da mesma maneira com que foi feita a curva de produção acumulada, foram realizadas as mesmas simulações com a curva de vazão. A Figura 5 ilustra a curva de treinamento da rede neural com a curva do simulador para a vazão de petróleo. O sinal azul representa o simulador, enquanto que a rede neural é representada pelo sinal verde. O conjunto de treinamento tem os dados dos 10 primeiros anos da simulação, ou seja, 120 meses.

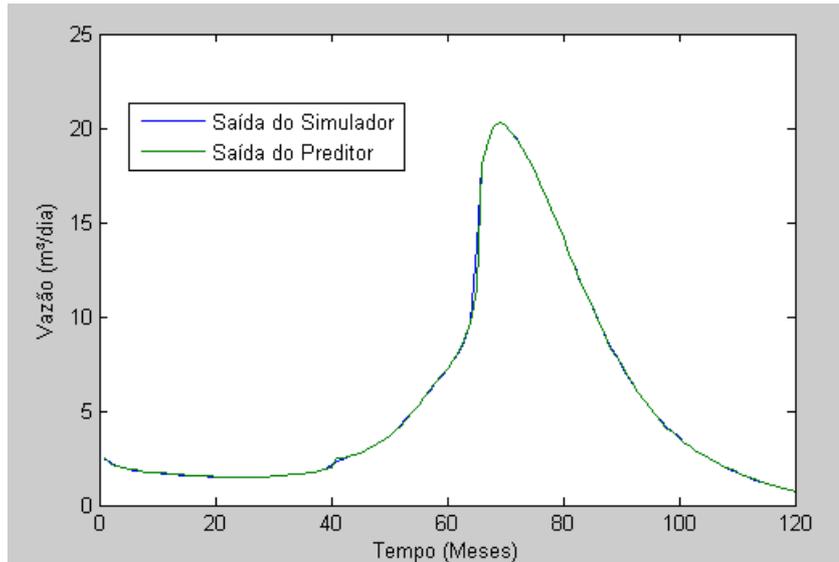


Figura 5: Treinamento para a curva de vazão

Na Figura 6 é ilustrado o gráfico utilizado para analisar a predição de passo simples com 9 passos adiante, realizada pela rede neural para a vazão de petróleo. Este gráfico mostra os sinais de saída do simulador e da rede NARX utilizada como preditor de passo simples. O sinal do preditor é representado pela linha verde, enquanto o sinal gerado pela saída do simulador é representado pela linha azul.

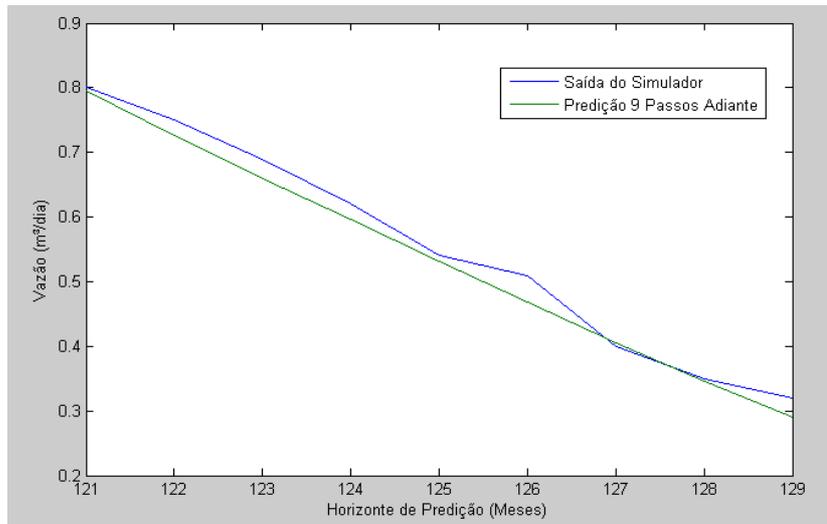


Figura 6: Sinal da vazão obtido pela predição de 9 passos

4 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 completção) 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 satisfatórios, constituindo-se 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.

5 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.
- 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.
- 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.
- 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.
- LOURAKIS, M. A Brief Description of the Levenberg-Marquardt Algorithm. Institute of Computer Science. Crete, Greece, 2005.
- 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.
- 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.
- 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.