

Aplicação de redes neurais artificiais no processo de ajuste de histórico

[Luís Augusto Nagasaki Costa](#)

"As RNA são capazes de captar com eficiência as não linearidades tipicamente presentes em problemas envolvendo estudos de reservatórios."

INTERESSES ESPECIAIS:

- [UNISIM](#)
- [Publicações UNISIM](#)
- [Portal de Simulação de Gerenciamento de Reservatórios](#)
- [UNIPAR](#)
- [Edições anteriores](#)

LINKS:

- [Unicamp](#)
- [Cepetro](#)
- [Dep. Eng. Petróleo](#)
- [Fac. Eng. Mecânica](#)
- [Ciências e Eng. de Petróleo](#)

PÓS-GRADUAÇÃO:

Ciências e Engenharia de Petróleo: interessados em Mestrado e Doutorado na área de Simulação e Gerenciamento de Reservatórios [cliquem aqui](#).

1. Introdução

A tarefa de ajuste de histórico é amplamente utilizada pelos profissionais envolvidos com o estudo de reservatórios, pois com o modelo ajustado é possível realizar previsões e estudo de estratégias de produção com maior confiabilidade. Para tal, o modelo de simulação deve ser ajustado para tentar reproduzir o comportamento observado no campo real. Isso pode ser obtido através da minimização de uma Função Objetivo (FO) que mede a qualidade do ajuste (diferença entre o modelo simulado e o histórico), em um processo em que os atributos incertos do reservatório são modificados.

Um dos problemas relacionados ao ajuste de histórico é o número de simulações e o tempo demandado para alcançar bons resultados. Dentre diversos procedimentos existentes para melhorar esse aspecto, a utilização de metamodelos gerados por Redes Neurais Artificiais (RNA) possui características promissoras, pois as RNA são, em geral, capazes de captar as não linearidades tipicamente presentes em problemas de estudo de reservatórios e os metamodelos são capazes de emular as simulações obtendo resultados semelhantes em tempo muito menor.

Costa (2012) realizou um estudo sobre aplicação de metamodelos gerados através de RNA como substitutos do simulador de escoamento, mostrando que a sua utilização pode agregar valor aos resultados.

2. Metodologia e aplicação

A metodologia básica utilizada por Costa (2012) consiste nas seguintes etapas:

Etapa 1: foram geradas as entradas e as saídas desejadas para treinar as RNA. As entradas foram geradas através da técnica do Hiper-cubo Latino (HL). Para o caso de estudo apresentado, a entrada consistiu em um modelo de simulação, que foi utilizado para gerar a curva de produção de água. Essa curva foi comparada com o histórico disponível e o afastamento entre eles foi calculado. A saída desejada consistiu nesse valor de afastamento.

Etapa 2: foi realizada a Análise de Sensibilidade (AS) para selecionar os atributos com maior influência na FO (afastamento da produção de água) e, dessa maneira, reduzir a complexidade do problema. O procedimento básico consistiu em variar o valor de um atributo para o seu máximo e mínimo, enquanto os demais são mantidos no valor do Caso Base, e avaliar a variação da FO. A sensibilidade consiste no coeficiente A, mostrado pela Equação 1.

$$A = \left(1 - \frac{A_{\text{ajustado}}}{B_{\text{base}}}\right) \cdot 100\% \quad (1)$$

Na Equação 1, Ajustado representa o afastamento do modelo ajustado (modificado) e Base representa o afastamento do Caso Base.

O atributo que teve a soma do coeficiente A maior que 20%, quando seu valor foi alterado para limite máximo e mínimo, foi utilizado para compor o conjunto de entrada para treinar as RNA.

Etapa 3: treinamento das RNA, em que os valores dos pesos da RNA foram ajustados utilizando o conjunto de treinamento gerado na Etapa 1.

Etapa 4: otimização dos atributos de reservatório e validação. Nessa etapa o metamodelo escolhido foi utilizado no lugar do simulador para realizar a varredura do espaço de soluções. A validação foi realizada avaliando o mínimo encontrado (atributos do reserva-

tório) com o simulador de escoamento e comparando as curvas de produção resultante com o histórico. Na validação, além de comparar os gráficos de produção dos modelos encontrados, foram comparados os indicadores de qualidade, que medem a redução no valor do afastamento relativamente ao Caso Base, ou seja, quanto que o modelo melhorou com relação ao Caso Base.

A Equação 1 mostra a expressão que calcula esse indicador. Ele varia de um valor negativo qualquer até 100%, em que valores positivos indicam melhora em relação ao Caso Base e 100% representa o ajuste perfeito. Valores negativos indicam que houve piora com relação ao Caso Base.

Etapa 5: retreinamento. Através da validação avaliou-se a proximidade da resposta com o histórico. No caso em que a resposta ainda não estava na precisão desejada, porém, com um erro pouco discrepante, um novo treinamento foi realizado ao redor do mínimo encontrado, ou seja, em uma área menor (refinada) do espaço de soluções.

A metodologia foi aplicada a um reservatório sintético, mostrado na Figura 1, com dezesseis atributos incertos.

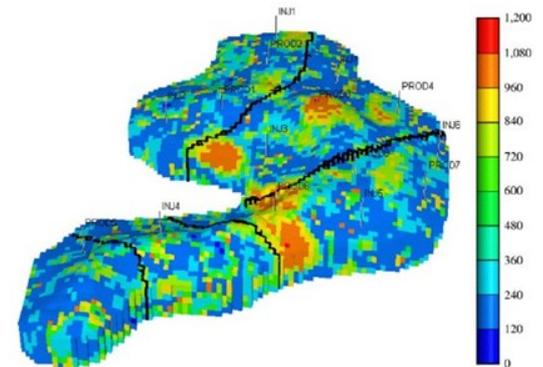


Fig. 1: Permeabilidade horizontal (md).

O reservatório é drenado por quinze poços verticais (oito produtores e sete injetores), de forma que a FO foi composta por oito componentes (afastamento com relação ao histórico, poço a poço, da produção de água). Com isso surgiram duas possíveis configurações de RNA: treinar oito RNA independentes com uma saída cada ou uma RNA com oito saídas. Através de testes realizados verificou-se que a utilização de uma RNA com oito saídas proporcionou melhores resultados, uma vez que possíveis inter-relações entre os poços puderam ser captadas. Assim, essa foi a configuração utilizada.

Com relação às entradas, através da AS foram selecionados nove dos dezesseis atributos para comporem o conjunto de entrada. Foram amostrados conjuntos com 100 e 250 pontos para treinar as RNA e gerar os metamodelos. Posteriormente, foram gerados mais 100 pontos a partir do metamodelo gerado com 100 pontos para avaliar o efeito do retreinamento.

3. Resultados

Na Tabela 1 são apresentados o afastamento (AF) e o indicador de qualidade (A) poço a poço e a média entre eles. Os nomes HL250, HL100 e HL100RTR correspondem aos metamodelos gerados com 250 e 100 pontos do HL e mais 100 pontos do

"A aplicação da metodologia permitiu obter bons ajustes com número reduzido de simulações em um caso prático de reservatório."

HL a partir do metamodelo HL100 (retreinamento), respectivamente. Pode-se observar que para a maioria dos poços foram obtidos bons ajustes com o metamodelo HL250, resultando em um valor médio de A de 88%. Mesmo com poucos pontos (HL100) uma boa média foi obtida (77%).

Tab. 1: Qualidade do ajuste dos modelos obtidos através da utilização dos metamodelos.

	AF - (m ³ /dia) ² e [A - (%)]							
	BASE		HL250		HL100		HL100RTR	
	AF	A	AF	A	AF	A	AF	A
PROD1	8106	22363	-176	7699	5	6338	22	
PROD2	36025	344	99	4373	88	928	97	
PROD3	266069	10707	96	19984	92	7074	97	
PROD4	48038	659	99	64579	-34	10022	79	
PROD5	95671	16008	83	2318	98	15565	84	
PROD6	6150	5970	3	1811	71	13479	-119	
PROD7	9132	615	93	2138	77	65	99	
PROD8	3659	44	99	5900	-61	480	87	
Média	59106	7089	88	13600	77	6744	89	

A comparação dos indicadores AF e A mostram que houve melhoras expressivas com relação ao Caso Base para os poços PROD2, PROD3, PROD4, PROD5, PROD7 e PROD8 para o metamodelo HL250. Uma análise mais detalhada desses resultados pode ser encontrada em Costa (2012).

Na Figura 2 apresenta-se a curva de produção de água para o poço PROD8, em que houve uma melhora significativa em relação ao Caso Base.

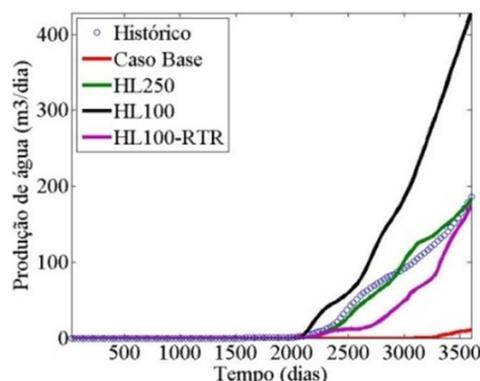


Fig. 2: Curva de produção de água do poço 8.

Com relação ao metamodelo HL100, apesar de melhorar bem o Caso Base, ainda houve alguns poços desajustados (Figura 2). Foi realizado, então, o retreinamento a partir desse metamodelo, amostrando mais 100 pontos e realizando-se novo treinamento e otimização. O resultado é apresentado na Tabela 1, em que se observa uma melhora de 89% (coeficiente A) em relação ao Caso Base. A Figura 2 mostra como o retreinamento melhorou a curva para o poço 8, com relação ao treinamento com 100 pontos.

Com o retreinamento foram utilizados, no total, 200 pontos (100 para treinamento e mais 100 para retreinamento), e obteve-se qualidade de ajuste se-

melhante ao treinamento com 250 pontos, demonstrando que o procedimento agrega valor aos resultados. Isso demonstra que, se usada num processo assistido, a RNA pode ser uma ferramenta útil. Mesmo para os poços que não ficaram bem ajustados, é possível realizar novas iterações e ajustar aqueles com resultados não muito adequados.

4. Considerações finais

Os resultados mostraram que metamodelos gerados através de RNA podem ser úteis como substitutos rápidos do simulador de escoamento no processo de ajuste de histórico. Apesar de não ser possível representar o simulador com grande precisão, pois se tratam de estruturas simplificadas, a sua utilização em etapas que demandam muitas simulações, como a etapa de otimização, pode contribuir para obtenção de resultados satisfatórios.

Nesse caso, a realização de um retreinamento melhorou os resultados, possibilitando obter ajustes aceitáveis com menos simulações. No entanto, se o treinamento identificar uma região de mínimo diferente da região de interesse, o retreinamento também pode conduzir a otimização a uma região errada (mínimo local). Entretanto, se a qualidade do ajuste for verificada no final do processo, isso pode ser corrigido em novas iterações.

Por isso, apesar da aplicação da ferramenta mostrar-se promissora, deve-se recorrer ao simulador de escoamento para obter uma validação final. No estágio atual de tecnologia, o uso do simulador é indispensável como etapa final do processo.

Com relação ao retreinamento outros procedimentos poderiam ser adotados. Uma possibilidade seria gerar os metamodelos com um número reduzido de amostras, realizar a otimização e, através da validação com o simulador, avaliar a possibilidade de retreinamento, podendo este ser em todo o espaço de busca dos parâmetros, em uma região menor ou em algumas regiões, a depender da avaliação dos resultados. Através desse procedimento iterativo de adição de amostras poderia se chegar a uma quantidade reduzida de pontos que proporciona ajustes aceitáveis.

5. Referências

Costa, L. A. N.; *Aplicação de Redes Neurais Artificiais no Processo de Ajuste de Histórico*; Campinas, 2012, 145pp, Dissertação (Mestrado em Ciências e Engenharia de Petróleo) - Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas.

Informações sobre o autor:

Luís Augusto Nagasaki Costa é engenheiro eletricitista pela UNESP e mestre em ciências e engenharia de petróleo pela UNICAMP e realiza pesquisas para o Grupo UNISIM desde 2009, na área de ajuste de histórico.

OPORTUNIDADES NO UNISIM:

Se você tem interesse em trabalhar ou desenvolver pesquisas no UNISIM, entre em contato conosco.

Interesse imediato em:

- Pesquisador na área de simulação, gerenciamento e caracterização de reservatórios.

Para mais detalhes, [clique aqui](#).



Grupo de Pesquisa em Simulação e Gerenciamento de Reservatórios

Depto. Eng. Petróleo
Fac. Eng. Mecânica
Centro de Estudos de Petróleo
Univ. Estadual de Campinas
Campinas-SP

Tel: 55-19-3521-1220

Fax: 55-19-3289-4916

unisim@dep.fem.unicamp.br

Para maiores informações, visite
<https://www.unisim.cepetro.unicamp.br>

O UNISIM é um grupo de pesquisa da UNICAMP (Departamento de Engenharia de Petróleo, Faculdade de Engenharia Mecânica, Centro de Estudos de Petróleo - CEPETRO) que tem como objetivo desenvolver trabalhos e projetos na área de simulação e gerenciamento de reservatórios.