



CONGRESSO BRASILEIRO  
DE ENGENHARIA QUÍMICA EM  
INICIAÇÃO CIENTÍFICA

21-24 Julho de 2019  
Uberlândia/MG



# CONTROLADORES NEURONAIS APLICADOS À PERFURAÇÃO DE POÇOS DE PETRÓLEO

R. G. C. FONSECA<sup>1</sup>, M. F. PETROCELI<sup>1</sup>, V. J. S. RIBEIRO<sup>1</sup>, G. F. M. OLIVEIRA<sup>1</sup> e M. P. VEGA<sup>1</sup>

<sup>1</sup> Universidade Federal Rural do Rio de Janeiro, Departamento de Engenharia Química  
E-mail para contato: vega@ufrj.br

**RESUMO** – A perfuração de poços de Petróleo é uma operação altamente complexa, custosa e uma grande área a ser explorada pela pesquisa. Sabendo que se trata de um processo de alta complexidade, torna-se extremamente importante o controle da pressão anular de fundo dentro da janela operacional, compreendida entre a pressão de poros e de fratura, visando assim uma maior segurança no processo de perfuração como um todo. A partir disso, realizam-se estudos acerca do controle da pressão anular de fundo em cenários de *kick* e perda de circulação. Com o objetivo de mitigar as flutuações de pressão causadas por tais distúrbios, desenvolveu-se um estudo de controle da pressão anular de fundo durante o processo de perfuração, aplicando-se controladores neuronaes, que são atrativos devido a habilidade em lidar com sistemas não-lineares e inerentemente transientes, como é o processo de perfuração. Este estudo foi realizado em uma unidade experimental que apresenta as principais características do processo de perfuração.

## 1. INTRODUÇÃO

A perfuração de poços de petróleo é realizada através do movimento rotativo conduzido à broca pela coluna de perfuração. Nesta operação, é injetado o fluido de perfuração através da coluna, que escoar pela broca em direção à região anular, a qual é delimitada pela parede do poço e a coluna de perfuração. O fluido de perfuração tem como finalidade resfriar e lubrificar a broca, carrear os cascalhos resultantes do processo de perfuração e imprimir pressão hidrostática do poço.

Alguns distúrbios podem ocorrer durante a perfuração, tais como *kick* e perda de circulação. Quando a pressão no interior do poço se torna maior que a pressão no interior da formação rochosa (reservatório), ocorre perda de fluido de perfuração para as formações adjacentes. Para as situações em que a pressão no interior do poço é menor que a pressão do reservatório, ocorre o influxo de fluidos nativos em direção ao poço, caracterizando o distúrbio de *kick*.

As redes neuronaes artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso central humano, sendo utilizadas na estimação ou aproximação de funções que dependem de múltiplas entradas. As redes neuronaes adquirem conhecimento a partir da aprendizagem de seu ambiente, armazenando as informações adquiridas através dos pesos sinápticos. A RNA pode ser caracterizada como um modelo não linear, sendo esta, útil na representação de dados de entrada/saída, na realização de predições temporais, na classificação



de dados e no reconhecimento de padrões. Além disso, não necessita da especificação de sua estrutura à priori, apresentando modelos mais flexíveis (HIMMELBLAU, 2000).

As Redes Neurais são posicionadas no sistema de controle, caracterizando o neurocontrolador. No presente trabalho, foram utilizados dois tipos de controlador neuronal: o direto e o indireto. O controlador neuronal direto é desenvolvido pela aplicação da modelagem inversa da dinâmica da planta, ou seja, a rede neuronal age diretamente como um controlador. O projeto do controlador neuronal indireto baseia-se no modelo neuronal do sistema a ser controlado. Neste caso, o controlador é desenvolvido a partir da modelagem da planta pela rede neuronal. O desenvolvimento do controlador neuronal indireto envolve duas etapas: a identificação da dinâmica da planta pela rede neuronal utilizando dados de treinamento; e o projeto de controle derivado do modelo de identificação neuronal (NGUYEN, 2003; HAYKIN, 2009).

Diante disso, neste trabalho será utilizado um controlador baseado em redes neurais para regular em linha o processo de perfuração para os fenômenos de *kick* de gás e perda de circulação, utilizando como variável manipulada o índice de abertura da válvula *choke*. Foi desenvolvida uma rede neuronal recursiva com retroalimentação da variável de saída, empregando dados atuais e passados de monitoramento de forma a permitir o aprendizado da dinâmica do processo. As validações do controle serão realizadas em unidade experimental que simula o processo de perfuração de poços de petróleo.

## 2. MATERIAIS E MÉTODOS

### 2.1. Unidade Experimental

A estrutura foi planejada para retratar o processo de perfuração de poços de petróleo, apresentada na Figura 1, está localizada no Laboratório de Escoamento de Fluidos - Giulio Massarani, nas dependências do Departamento de Engenharia Química, na Universidade Federal Rural do Rio de Janeiro (UFRRJ).

Figura 1 – Unidade Experimental.



A unidade conta com tanques de lama, bombas de deslocamento positivo, válvulas automatizadas, compressor, medidores de vazão e densidade, transdutores de pressão,



tubulações de água (fluido utilizado para os testes) e de gás. A estrutura foi planejada para simular a coluna de perfuração e a região anular através de uma tubulação em formato “U”, separada por uma válvula que simula a restrição típica de uma broca de perfuração. A unidade conta também com um tanque de pressão que representa a rocha reservatório através do acoplamento com a região anular, onde é possível estudar os fenômenos de *kick* e perda de circulação. O tanque de pressão possui entrada e saída de ar comprimido que controlam a pressão interna do tanque. Para reduzir a pressão, a válvula de saída libera ar comprimido para a atmosfera, deste modo, é possível controlar a pressão em tempo real através da manipulação das válvulas.

A fim de controlar a unidade experimental, foi desenvolvido um programa de monitoramento e controle em linguagem C++. Este programa permite monitorar o acoplamento coluna/tanque reservatório, ou cada sistema isoladamente, monitorando vazão, pressão e abertura das válvulas em linha. É possível ajustar os parâmetros do controlador e selecionar variáveis manipuladas (abertura da válvula *choke* ou vazão da bomba) e controlar a pressão do tanque reservatório (pressão de poros). Dessa forma, é possível inserir dados em tempo real na rede neuronal para fins de treinamento.

## 2.2. Metodologia

Para que seja implementado um controlador baseado em redes neuronais, é necessário que haja a identificação da unidade. A identificação é realizada através de treinamentos da rede, que são realizadas repetidamente para um conjunto de exemplos diversos, até que o estado estacionário seja atingido e não ocorram alterações significativas dos pesos sinápticos.

Os testes de treinamento implementados na planta foram feitos em triplicata, empregando-se como dados de treinamento três, cinco e sete dados passados de pressão anular de fundo, sendo associados a quantidades distintas de neurônios na camada oculta (cinco, sete e nove), conforme o método de Pollard (1992). Foram realizados treinamentos para *kick* de gás e perda de circulação, tendo como variável manipulada o índice de abertura da válvula *choke*, aplicando-se uma vazão constante para a alimentação da coluna de perfuração.

A configuração utilizada foi a *feedforward* de múltiplas camadas, a qual apresenta várias camadas ocultas o que a torna a rede mais sensível. O algoritmo de aprendizagem é o *backpropagation* que permite que o sinal de entrada ao chegar na última camada, gere um erro associado ao padrão fornecido, que é retropropagado para a camada de entrada. Desse modo, os pesos sinápticos são ajustados a fim de que o erro quadrático médio entre a entrada e a saída seja minimizado (ARBIB, 2003).

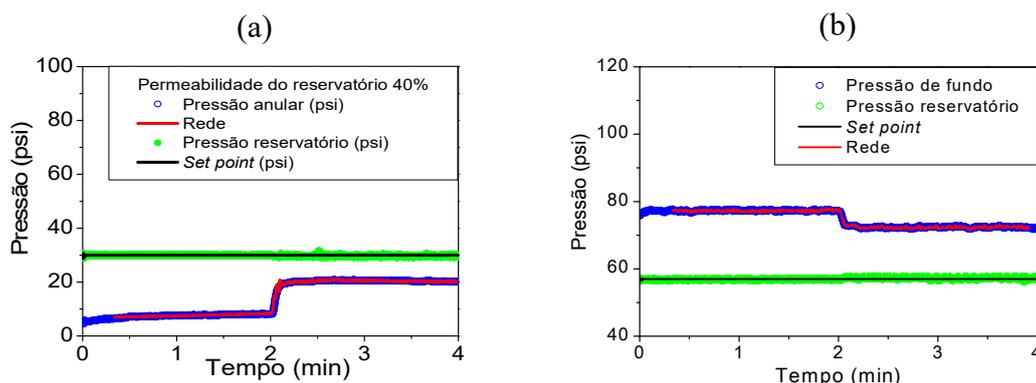
## 3. RESULTADOS E DISCUSSÕES

### 3.1. Treinamento da Rede Neuronal

Para avaliação dos cenários de *kick* e perda de circulação, foram realizados testes de treinamento da rede nos quais fixou-se a pressão do reservatório 20 psi acima da pressão registrada no fundo do anular, para os casos de *kick*, e 20 psi abaixo, para perda de circulação. Nestes treinamentos, com o sistema em estado estacionário, aplica-se uma perturbação em um

tempo igual a 2 minutos, através da abertura da válvula de permeabilidade (Figura 2). Observa-se que para uma mesma magnitude de degrau, a resposta do sistema (ganho e constante de tempo) foi diferente para ambos os casos (Figuras 2 a e b). Dessa forma, o sistema não obedece ao princípio da superposição, apresentando não linearidade, o que requer a implementação de um controlador não linear.

Figura 2 – (a) Treinamento da rede neuronal com nove neurônios na camada oculta para *kick* de gás, (b) Treinamento da rede neuronal com sete neurônios na camada oculta para perda de circulação.



Pode-se observar que a rede apresentou um bom resultado, conseguindo responder de forma eficiente os distúrbios apresentados.

### 3.2. Controlador Via Rede Neuronal - Método Indireto

Inicialmente, foi realizado o treinamento da rede neuronal através de perturbações na variável manipulada, com objetivo de gerar dados de aprendizagem. Após, ativa-se o controlador, mantendo o sistema em estado estacionário. No ponto 1, foi implementado um distúrbio no sistema através da válvula de permeabilidade, que simula a fratura da rocha reservatório. Para que o *kick* de gás seja controlado, a pressão anular de fundo deve ser superior a pressão de poros do reservatório, como pode ser visto na Figura 3. Para a perda de circulação, mostrada na Figura 4, a pressão anular de fundo deve ser reduzida. Na Figura 4a, a dispersão inicial, antes do ponto 1, se refere ao processo de treinamento. Conforme pode ser observado, os controladores neuronais foram eficientes em conduzir a pressão anular de fundo para os *setpoints* de operação, após a implementação do distúrbio (após o ponto 1).

### 3.3. Controlador Via Rede Neuronal Inversa – Método Direto

Assim como o controlador indireto, o controlador direto utilizou o treinamento prévio da rede. Após, ativa-se o controlador, mantendo-se a pressão anular de fundo no *setpoint* de operação (estado estacionário). No ponto em destaque, implementa-se a perturbação no sistema através da válvula de permeabilidade. Como pode ser observado, a resposta da variável manipulada é estimada pelo controlador eficientemente para regular a pressão anular de fundo, conforme pode ser observado nas Figuras 5 e 6. Pode ser observado que as ações da variável manipulada (válvula *choke*) foram eficazes para rejeitar a perda de circulação e o *kick*, assegurando perfuração segura, dentro de janela operacional.

Figura 3 - (a) *Kick* de gás com 40% de permeabilidade da rocha reservatório, (b) Resposta da variável manipulada.

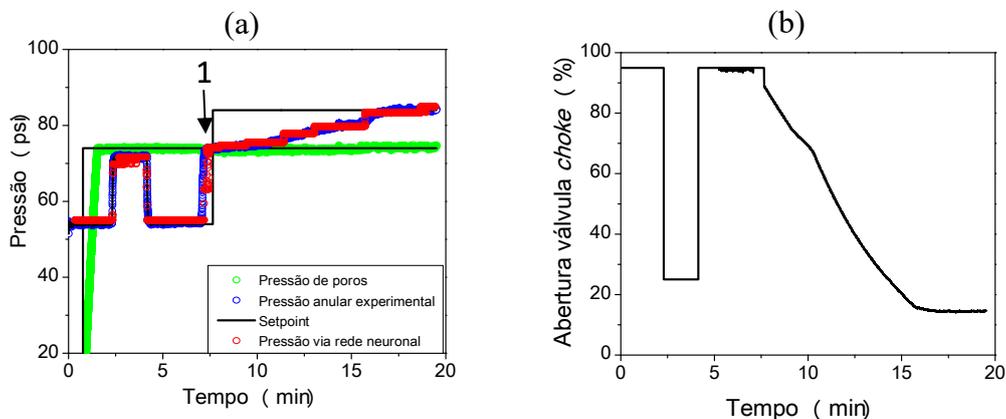


Figura 4 – (a) Perda de circulação com 40% de permeabilidade da rocha reservatório, (b) Resposta da variável manipulada.

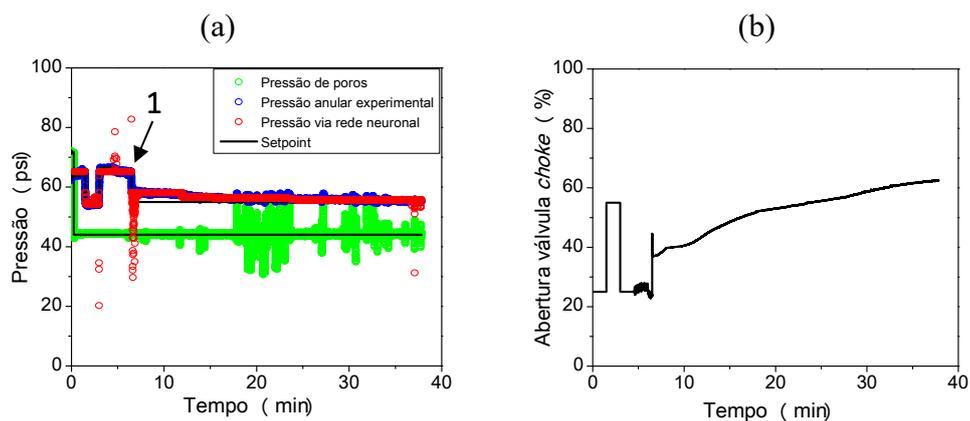


Figura 5 – (a) Controle da pressão anular frente *kick* de gás com válvula de permeabilidade em 50%, (b) Resposta do controlador neuronal inverso.

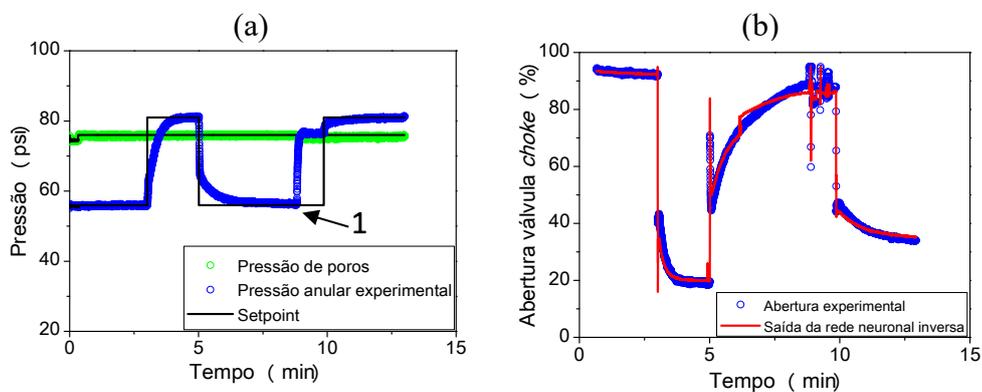
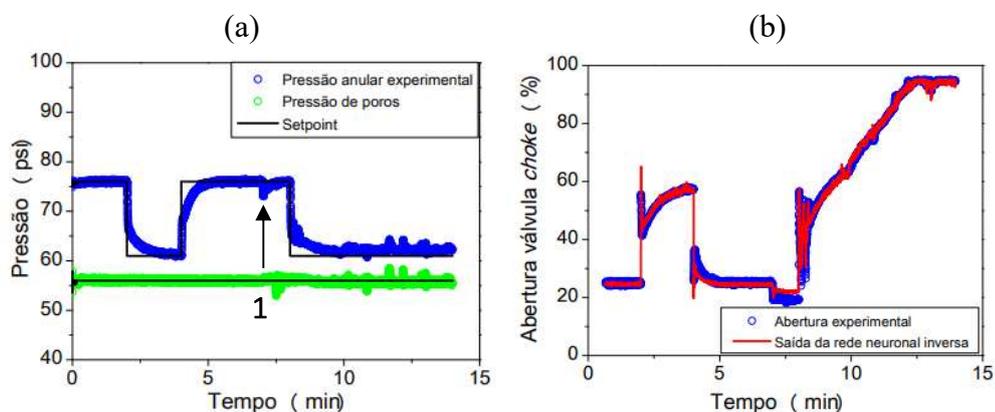


Figura 6 – (a) Controle da pressão anular frente a perda de circulação com válvula de permeabilidade em 60%, (b) Resposta do controlador neuronal inverso.



## 4. CONCLUSÃO

É possível notar que a rede apresentou um bom desempenho nos testes de treinamento para identificação da unidade. Nos experimentos de controle, ambos os controladores neurais se mostraram eficientes em controlar a pressão anular de fundo, frente a distúrbios. O desempenho dos controladores não lineares foi superior ao do controlador clássico PI. Diante dos resultados apresentados é viável a implementação em tempo real de um controlador baseado em rede neuronal para regular a pressão anular de fundo durante o processo de perfuração de poços de petróleo.

## 6. REFERÊNCIAS

- HAYKIN, S. *Neuronal networks and learning machines.*, 3<sup>a</sup> ed., Prentice - Hall, 1996.
- HIMMELBLAU, D. M. Applications of Artificial Neuronal Networks in Chemical Engineering. *Korean J Chem. Eng.*, 17(4), p. 373-392, 2000.
- NGUYEN, H.T. *A first course in fuzzy and neuronal control.* Chapman & Hall/CRC, 2003.
- POLLARD, J. F., BROUSSARD, M. R., GARRISON, D. B., SAN, K. Y. 1992. Process identification using neural networks. *Comput. Chem. Eng.* 16:253-270.