

9º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



9º CONGRESSO
Brasileiro de P&D em
PETRÓLEO E GÁS

Maceió, AL
de 09 a 11 de novembro
2017

Realização:



ABPG
ASSOCIAÇÃO BRASILEIRA DE P&D EM
PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Detecção de escoamento bifásico em BCS utilizando sinais de vibração com redes neurais do tipo MLP e ELM

AUTORES:

Felipe de Castro Teixeira Carvalho, Alberto Luiz Serpa, Natache do Socorro Dias Arrifano Sassim, William Monte Verde

INSTITUIÇÃO:

Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Departamento de Mecânica Computacional, Centro de estudos de Petróleo (CEPETRO)

Este Trabalho foi preparado para apresentação no 9º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás - 9º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás - ABPG, no período de 09 a 11 de novembro de 2017, em Maceió/AL. 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 9º PDPETRO.

Detecção de escoamento bifásico em BCS utilizando sinais de vibração com redes neurais do tipo MLP e ELM

Abstract

In oil exploitation, the industry occasionally has to increment the fluid energy. In order to provide this energy increment the electrical submersible pumps (ESP) are widely used in oil exploitation. Moreover, due to the reservoir conditions a biphasic flow may emerge and the ESP are sensitive to the gas volume in the flow. In addition, the knowledge of the gas volume in a two-phase flow condition results in valuable information about the overall flow condition. Thus, this work evaluates the use of machine learning techniques, such as multilayer perceptron (MLP) and extreme learning machine (ELM) to devise a regressor with spectrum of the ESP mechanical vibration as input and the gas volume as output.

1 Introdução

Na exploração de petróleo, a indústria frequentemente se depara com a necessidade de incrementar energia ao fluido para que este transponha o percurso desejado. Tal necessidade provém desde do aumento da produção de petróleo, em poços surgentes, a características intrínsecas do reservatório o qual é inviável sem o fornecimento de energia. A despeito do aumento da produção em poços surgentes, o incremento de energia nestes também está relacionado à depleção do poço, pois a medida que o petróleo é extraído, a pressão diminui e por consequência a produção é reduzida. O processo de fornecer energia ao fluido é denominado de elevação artificial (Zhou e Sachdeva, 2010).

A elevação artificial possui diversos métodos os quais são recomendados cada qual em condições específicas. Portanto, a escolha de um método adequado está atrelada a fatores como vazão desejada, profundidade, características do fluido, custo operacional e tipo de completação. Neste contexto, as bombas centrífugas submersas (BCS) são amplamente utilizadas na exploração de petróleo (Zhou e Sachdeva, 2010; Brinner *e outros*, 2004; Pineda, 2016).

Em condições de produção, a depleção do reservatório de petróleo ocasiona uma redução de pressão deste. Consequentemente, este pode ficar abaixo da pressão de saturação resultando assim em uma mistura bifásica. Ao determinar a fração de gás, volume de gás presente no escoamento, é possível obter diversos parâmetros relativos ao escoamento em questão, tais como, densidade e viscosidade da mistura e velocidade média da mistura. Ademais, a fração de gás é crucial em modelos mecanicistas que predizem o padrão de escoamento e sua transição (Shoham, 2006).

Dado que a BCS é amplamente utilizada no mundo pela indústria de exploração de petróleo, estudos que visam aprimorar sua operação sob condições de um escoamento multifásico são relevantes. Além disso, o trabalho apresentado por Rodriguez (2016) correlacionou com desempenho razoável, o espectro de vibração de uma BCS com a fração volumétrica de gás por meio de redes neurais do tipo *multilayer perceptron*. Dessa forma, este trabalho propõe o uso de redes neurais do tipo *multilayer perceptron* e *extreme learning machines*, capazes de correlacionar o espectro de vibração de uma BCS com a fração de gás presente no escoamento.

2 Metodologia

2.1 Multilayer perceptron

As redes neurais *multilayer perceptron* (MLP) são formadas basicamente por três camadas distintas, uma camada de entrada, uma ou mais camadas ocultas e por fim uma camada de saída. Na camada de entrada

têm-se os dados os quais se deseja classificar ou fazer uma regressão e na camada de saída têm-se as saídas desejadas para uma dada entrada (Haykin, 2008). Conforme Haykin (2008), é por meio do ajuste dos pesos dos neurônios presentes nas camadas ocultas que a rede neural é capaz estabelecer uma relação entre a camada de entrada e a camada de saída.

O ajuste dos pesos de cada neurônio de cada camada oculta é feito mediante a minimização de um de erro. Neste trabalho foi utilizado o erro quadrático médio (*MSE*). Assim, pelo algoritmo *backpropagation*, o ajuste dos pesos da rede neural se torna um problema de minimização de um erro. Pode-se então utilizar ferramentas de otimização, como método de Newton, Quase-Newton, gradientes conjugados para treinar a rede (Haykin, 2008). Neste trabalho foi utilizado o método Quase-Newton com o algoritmo BFGS.

A implementação da rede MLP a ser utilizada neste trabalho foi feita por meio da biblioteca para a linguagem de programação Python, *scikit-learn*. Por fim, as arquiteturas a serem avaliadas para a rede neural MLP consistiu na variação do número de neurônios de 30 em 30 de 200 a 590 neurônios, com uma única camada oculta. As funções de ativação utilizadas serão a tangente hiperbólica e a *rectified linear unit* (ReLU).

2.2 Extreme learning machines

De forma semelhante às MLP as *extreme learning machines* (ELM) são redes neurais não-recorrentes (*feedforward*) apresentadas por Huang e outros (2004). As principais diferenças entre a ELM e a MLP estão na sua arquitetura e como são treinadas. A ELM admite apenas uma única camada oculta e suas funções de ativação são determinadas de forma aleatória dentro de um conjunto de funções. Este conjunto pode ser constituído, por exemplo, por funções trigonométricas, funções de base radial, tangente hiperbólica, função sinal. Os pesos iniciais da camada oculta são determinados aleatoriamente.

Assim tem-se que a ELM pode ser dada por:

$$s_k = \sum_{j=1}^n w_j f_j(\mathbf{v}_j, b_j, \mathbf{x}_k) + w_0 \quad (1)$$

Onde as variáveis $\mathbf{v}_j$ e w_j referem-se aos pesos da camada de oculta e saída respectivamente. Já as variáveis b_j e w_0 referem-se aos bias da camada de oculta e da camada de saída respectivamente.

O treinamento da ELM, diferentemente da MLP, não requer conhecimento do gradiente nem da matriz Hessiana, uma vez que os únicos pesos a serem ajustados são os da camada de saída (w_j) enquanto os pesos da camada oculta são mantidos constantes. A função de custo normalmente utilizada é o *MSE*. Assim, o treinamento consiste basicamente na utilização de mínimos quadrados para ajustar apenas os pesos da camada de saída mantendo os pesos da camada oculta aleatórios. Contudo, tal abordagem é não suficiente para obter resultados satisfatórios sendo necessária a regularização do modelo, por exemplo, pela distância euclidiana.

Neste trabalho, a ELM foi implementada utilizando a linguagem de programação Python, com a técnica de regularização pela distância euclidiana (*ridge regression*) e com validação cruzada de *k-pastas*. As funções de ativação da ELM foram determinadas aleatoriamente entre as funções sigmóide, tangente hiperbólica, ReLU e gaussiana. Já o número de neurônios foi avaliado de 200 em 200 até 2400 neurônios. O melhor coeficiente de ponderação da regularização foi definido após executar o treinamento com validação cruzada com 2000 parâmetros de regularização distribuídos linearmente no intervalo de 10^{-7} a 10.

2.3 Aquisição dos dados

Os experimentos foram realizados por Rodriguez (2016) nas instalações do Laboratório Experimental de Petróleo Kelsen Valente (LABPETRO) do Centro de Estudos de Petróleo (CEPETRO) da Universidade Estadual de Campinas. Para tal foi utilizado uma BCS modelo *GN5200*, série 540, de três estágios operando a 3500rpm com uma pressão na entrada de 600kPa . Com uma mistura viscosa de glicerina e ar, variando-se a fração volumétrica de gás de 0,035% a 8,95% com ao todo 13 pontos de fração de gás. O layout da bancada pode ser visualizado na Figura 1.




Figura 1: Layout esquemático da bancada utilizada para medição dos sinais de vibração (Rodriguez, 2016).

Para medição dos sinais de vibração utilizou-se acelerômetros piezoelétricos da marca PBC Piezotronics modelo 352C65, instalados na carcaça da BCS. Já para o sistema de aquisição de dados foi utilizado o sistema Scada *SCR05* de 16 canais da empresa *LMS*. O sensor foi instalado na posição 0.6m em X com uma orientação de 90° em X, 90° em Y e 0° em Z, conforme o sistema de coordenadas mostrado na Figura 2.




Figura 2: Sistema de coordenadas da BCS (Rodriguez, 2016).

A medição dos sinais de vibração foi feita com uma frequência de amostragem de $12,8\text{kHz}$. Ademais, Rodriguez (2016) determinou o espectro a cada 500ms durante um tempo de captura de 30 segundos. Portanto, tem-se uma resolução do espectro de 10Hz , totalizando 641 frequências, de 0Hz a 6400Hz . Como pode ser observado, a maior frequência utilizada é a metade da taxa de amostragem. Tal abordagem deve-se ao interesse em evitar o efeito Nyquist. Além disso, o espectro foi obtido utilizando a transformada rápida de Fourier (FFT) com a janela do tipo Hanning e amplitude em termos do valor RMS (*Root Mean Square*) (Rodriguez, 2016).

Pode-se estimar de forma média e aproximada a fração de gás pela lei dos gases ideais para o tempo de captura. Para tanto utiliza-se as variáveis de estado, como pressão, vazões mássicas, viscosidades e densidades, variáveis medidas na bancada. É importante notar que em condições de operação, não se tem a informação da vazão mássica do gás presente na bomba nem a aproximação para gases ideais é adequada, dada a composição química do gás presente no escoamento.

2.4 Pré-processamento dos dados

Para se analisar o comportamento da BCS com diferentes frações volumétricas de gás, é apresentado na Figura 3, o espectrograma do sinal de vibração na carcaça da BCS para diferentes frações de vazio durante um tempo de medição de 30 segundos. Nesta figura, observa-se que há uma diferença notável entre os espectrogramas que representam uma fração volumétrica de gás menor e os que representam uma fração volumétrica de gás maior, sobretudo em frequências acima de 3000 Hz .




Figura 3: Espectrograma do sinal de vibração na carcaça da BCS.

É possível observar na Figura 3, que apesar dos espectrogramas serem diferentes para cada fração volumétrica de gás, há uma variação considerável dos espectros no que diz respeito às amplitudes das respostas nas frequências. Tal variação pode ser melhor observada na Figura 4, onde para uma fração volumétrica de gás de 8,95%, observa-se que as amplitudes das respostas nas frequências apresentaram um elevado desvio padrão relativo (RSD) entre cada espectro obtido ao longo dos 30s de medição.

Tal comportamento pode ser justificado pelo fato do escoamento bifásico poder ser considerado como pseudo-permanente, onde o comportamento momentâneo pode apresentar elevadas variações, mas o comportamento ao longo do tempo tender a uma média.




Figura 4: Espectros do sinal de vibração para uma fração volumétrica de gás de 8,95%.

Essa condição pode vir a ser um agravante considerável na utilização das técnicas a serem desenvolvidas neste trabalho, uma vez que o valor objetivo do regressor a ser treinado, foi obtido de forma média para todo intervalo de medição. Ou seja, tem-se em todas as entradas um desvio padrão elevado cuja regressão é um valor fixo determinado para todo o intervalo de medição. Portanto, para contornar esse problema, o espectro será dividido em vários subgrupos sequenciais e destes será feita uma média para cada frequência.

2.5 Separação dos Dados

Segundo Haykin (2008), as redes neurais que possuem uma boa capacidade de generalização retornará um correto mapeamento entre a entrada e a saída, mesmo que as entradas sejam ligeiramente diferentes das utilizadas na etapa de treinamento. Contudo, devido às características da arquitetura e do treinamento, as redes neurais podem acabar memorizando os dados do conjunto de treinamento e não aproximar a função que representa o mapeamento entrada e saída, caracterizando assim o sobre-ajuste (*overfitting*). Além disso, conforme Haykin (2008), a utilização de técnicas de validação cruzada é recomendada para se obter redes neurais com uma boa generalização.

Visando reduzir o RSD médio do espectro, mas sem reduzir de forma significativa o número de amostras existentes para treinamento e teste, foi estabelecido 5 espectros por subgrupo. Determinado o número de espectros que contera cada subgrupo, o conjunto de dados resultante foi dividido basicamente em dois, um para treinamento e validação e um segundo para teste. O conjunto de treinamento e validação foi estabelecido utilizando a técnica de validação cruzada de *k-pastas* com 5 pastas. Já o conjunto teste, foi constituído por cerca de 10% de todos os dados disponíveis e foram obtidos aleatoriamente.

3 Resultados

Para avaliar o desempenho das redes neurais ELM e MLP treinadas, foi utilizado o coeficiente de determinação (R^2) e uma regressão linear entre a saída das redes e os valores desejados. Assim, tem-se que a inclinação dessa reta é dada pelo coeficiente a e o deslocamento da reta no eixo vertical dado pelo coeficiente b . Dessa forma, a arquitetura que apresentar um valor de R^2 e a mais próximo de 1 e o valor de b mais próximo de 0 possui o melhor desempenho.

Para determinar as arquiteturas que serão testadas com o conjunto de teste, foram escolhidas as duas melhores redes neurais de cada técnica, tendo como base o valor destes coeficientes perante ao conjunto de validação. Assim, para comparar as diferentes arquiteturas das redes neurais ELM e MLP treinadas, tem-se nas Figuras 5 e 6 os valores de R^2 , a e b para as redes ELM e MLP respectivamente.




Figura 5: Valor do R^2 e dos coeficientes a e b para a ELM.




Figura 6: Valor do R^2 e dos coeficientes a e b para a MLP.

Na Figura 5 observa-se que a maioria das arquiteturas da rede neural ELM apresentaram resultados satisfatórios, com valores de R^2 e a próximos a 1 e valores de b próximos a 0, exceto para a arquitetura com 200 neurônios. Preferindo arquiteturas com menor número de neurônios e que obtiveram um resultado satisfatório, foram escolhidas as arquiteturas com 600 e 1800 neurônios.

Como pode ser observado na Figura 6, diferentemente das redes neurais ELM as redes neurais MLP apresentaram valores de R^2 e a próximos de 0, 8 e valores de b entre aproximadamente 0, 1 e 0, 2. Utilizando

o mesmo critério para escolha das arquitetura das redes neurais ELM, escolheu-se as redes neurais MLP que possuem 290 e 560 neurônios com a função de ativação ReLU.

Assim, utilizando as arquiteturas escolhidas com o conjunto de teste, tem-se nas Figuras 7, 8, 9 e 10 a fração volumétrica de gás medida e a obtida pelas técnicas ELM e MLP na forma de uma regressão de linear. Por fim, tem-se na Tabela 1 os valores de R^2 , a e b obtidos para as quatro arquiteturas selecionadas.




Figura 7: ELM com 600 neurônios.




Figura 8: ELM com 1800 neurônios.




Figura 9: MLP com 290 neurônios e função de ativação ReLU.




Figura 10: MLP com 560 neurônios e função de ativação ReLU.

Tabela 1: Valor de R^2 e dos coeficientes a e b para o conjunto de teste,

Rede	R^2	a	b
ELM - 600 Neurônios,	0,8607	0,8316	0,3744
ELM - 1800 Neurônios,	0,7894	1,0219	0,2663
MLP - 290 Neurônios, ReLU,	0,7095	1,1107	0,0819
MLP - 560 Neurônios, ReLU	0,8304	0,8475	0,5069

Como apresentado na Tabela 1 e nas Figuras 7, 8, 9 e 10, a rede neural que apresentou o melhor desempenho para o conjunto de teste foi a ELM com 600 neurônios. Tal arquitetura possui o maior valor de R^2 , além de possuir a metade do conjunto de teste dentro de um envelope de erro de 10%. Possuindo apenas 2 pontos fora de um envelope de erro de 30% e o restante dentro do envelope de erro de 20%.

É possível observar também que a rede MLP com 590 neurônios apresentou um resultado satisfatório para frações de vazio mais elevadas, tendo todas as frações volumétricas de gás acima de 2% dentro do envelope de erro de 20%. Tal desempenho reflete no valor de R^2 dessa arquitetura, o qual possui o segundo maior valor obtido dentro das arquiteturas testadas. Além disso, observa-se também que ambas arquiteturas escolhidas da técnica MLP tiveram a função ReLU como função de ativação, demonstrando que para este caso tal função de ativação foi mais adequada.

Como a ELM apresentou um resultado notoriamente superior perante ao conjunto de validação. Acredita-se que as redes neurais ELM escolhidas se ajustaram de forma exagerada ao conjunto de treinamento, caracterizando assim um sobre-ajuste nas redes neurais ELM escolhidas.

4 Conclusões

Dados os resultados e análises apresentadas na Seção 3, tem-se que tanto as redes MLP e as redes ELM puderam realizar uma regressão entre o espectro de vibração de uma BCS com a fração de gás presente no escoamento. Todavia, a rede neural que apresentou o melhor resultado foi uma ELM com 600 neurônios na camada oculta. Como mencionado na Seção 3, há indícios que as redes ELM treinadas possam estar sofrendo de sobre-ajuste, dado o desempenho notoriamente inferior para o conjunto de teste. Por isso, seria interessante para trabalhos futuros averiguar o uso de outros regularizadores como *LASSO* e *Elastic Net*.

Conclui-se que há uma relação entre o espectro de vibração da carcaça de uma BCS com a fração volumétrica de gás presente no escoamento, devido aos resultados apresentados na Seção 3 e o espectrograma observado na Seção 2.4. Contudo, os sinais de vibração da carcaça da BCS são diretamente influenciados pela montagem deste na bancada. Portanto, para se obter uma técnica de medição de fração volumétrica de gás na BCS baseada em sinais de vibração, há a necessidade de maiores estudos sobre a influência do gás presente no escoamento na vibração da carcaça da BCS.

Ademais, para trabalhos futuros sugere-se utilizar técnicas de redução dimensional, como redes neurais *autoencoders* e averiguar o seu impacto no desempenho das redes neurais ELM e MLP. Uma vez que o problema estará em uma dimensão menor pode-se ter uma redução no sobre-ajuste. Por fim, sugere-se também para trabalhos futuros a comparação de redes convolucionais com estas obtidas neste trabalho.

Agradecimentos

Os autores agradecem a Queiroz Galvão E. P., ANP “Compromisso de Investimentos com Pesquisa e Desenvolvimento” e PRH/ANP, e ao FAEPEX-UNICAMP (processo 519.292-3227/16) pelo apoio financeiro para este trabalho. Os reconhecimentos também são estendidos ao CEPETRO / UNICAMP e ao grupo ALFA (Artificial Lift Flow Assurance Research Group).

Referências Bibliográficas

- BRINNER, T.R.; ATKINS, J.D. e DURHAM, M.O. Electric submersible pump grounding. **IEEE Transactions on Industry Applications**, v. 40, n. 5, 1418–1426, 2004.
- HAYKIN, S. **Neural networks and learning machines**, v. 3. Pearson Upper Saddle River, NJ, USA:, 2008.
- HUANG, G.B.; ZHU, Q.Y. e SIEW, C.K. Extreme learning machine: a new learning scheme of feed-forward neural networks. In **Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on**, v. 2, pp. 985–990. IEEE, 2004.
- PINEDA, Luis Fernando Ruiz. **Controle do Ponto de Operação de Bombas Centrífugas Submersas em Escoamento Líquido-Gás Usando Redes Neurais**. 2016. Dissertação de mestrado. Universidade Estadual de Campinas.
- RODRIGUEZ, Carlos Uriel Cortés. **Identificação da fração de gás em Bombas Centrífugas Submersas através de Redes Neurais Artificiais**. 2016. Dissertação de mestrado. Universidade Estadual de Campinas.
- SHOHAM, O. **Mechanistic modeling of gas-liquid two-phase flow in pipes**. Richardson, TX: Society of Petroleum Engineers, 2006.
- ZHOU, D. e SACHDEVA, R. Simple model of electric submersible pump in gassy well. **Journal of Petroleum Science and Engineering**, v. 70, n. 3, 204–213, 2010.