

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:

CONTROLE INVERSO DIRETO DE BOMBA CENTRÍFUGA SUBMERSA USANDO REDES NEURAIS ARTIFICIAIS E REDES NEURO-FUZZY

AUTORES:

Luis Felipe B. Salamanca, Alberto L. Serpa, Natache A. Sassim, Jorge L. Biazussi, William M. Verde

INSTITUIÇÃO:

Departamento de Mecânica Computacional – Faculdade de Engenharia Mecânica, Centro de Estudos de Petróleos – CEPETRO, Universidade Estadual de Campinas – UNICAMP

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.

CONTROLE INVERSO DIRETO DE BOMBA CENTRÍFUGA SUBMERSA USANDO REDES NEURAIS ARTIFICIAIS E REDES NEURO-FUZZY

Abstract

A direct inverse controller based on a Neuro-Fuzzy system and artificial neural networks is designed to control an electrical submersible pump (EPS) operating with a two-phase flow (liquid-gas). To use this control technique, it was necessary to obtain experimental data from a test bench that uses an ESP. The purpose of the controller is to keep the system as close as possible to the given reference in a safe operating range according to the operating conditions. This controller was tested for near-reality conditions, simulating a slug flow.

Introdução

Na indústria petrolífera existem diferentes meios que são usados para a elevação do petróleo do poço até a superfície, que dão origem aos métodos de elevação natural ou artificial existentes. Dentre os métodos de elevação artificial, destaca-se o bombeio centrífugo submerso.

A bomba centrífuga submersa (BCS) é projetada para acionamento somente de líquidos, embora em certas condições, a pressão no espaço anular (espaço entre a carcaça do motor e a parede do poço) diminua e inicie a formação de bolhas. Neste momento há escoamento bifásico. Tanto a presença de gás livre na sucção, como a viscosidade do fluido, afeta o desempenho da bomba em termos de altura, eficiência e potência.

Para a indústria petrolífera é essencial determinar e controlar o desempenho das bombas centrífugas submersas operando tanto com fluido monofásico como com bifásico. Neste caso, é necessário controlar a vazão de sucção ou o ganho de pressão por meio da rotação da bomba, sendo possível variar o ponto de operação, e assim, evitar problemas na sucção e danos nos equipamentos.

Neste trabalho, é proposto um controlador para uma BCS operando com escoamento bifásico (água-ar) baseado em inteligência artificial. É desejado que esse controlador seja capaz de manter qualquer ponto de referência que seja dado independente das perturbações que existam.

O controlador foi testado para diferentes condições de operação considerando sinais de referências em degrau, rampa e pulsos. Para estas condições, o controlador foi perturbado, simulando um escoamento pistonado com bolsões de gás para validar os resultados do controlador em uma malha fechada.

Metodologia

Para projetar o controlador foi necessário obter o modelo dinâmico da bomba centrífuga a controlar, e para isso foram usadas as Redes Neurais Artificiais (RNA) como ferramenta para a modelagem de sistemas baseados em bancos de dados (Nørgaard *e outros*, 2004). Para modelar um sistema baseado em RNA, deve-se realizar quatro etapas básicas: coleta de dados, seleção da estrutura de modelagem, estimativa do modelo e validação.

A coleta dos dados foi feita de forma experimental em uma bancada de testes de BCS no Laboratório Experimental de Petróleo (LABPETRO), no Centro de Estudos do Petróleo (CEPETRO) da Universidade Estadual de Campinas. Este sistema opera com uma vazão de água de até 70 m³/h e com pressão de até 1 MPa na entrada e 2 MPa na linha de retorno. A bomba testada foi uma bomba P100

Série 538 construída por três estágios. Para maior informação dos testes feitos ver Biazussi (2014). Das variáveis medidas nos experimentos a rotação (ω), pressão de sucção (P_e) e o ganho de pressão (ΔP) foram usados para a modelagem da RNA assim como a vazão volumétrica de líquido (Q_l) e gás (Q_g). Os dados obtidos para a modelagem do desempenho da BCS podem ser observados na Tabela 1.

Tabela 1: Dados usados para modelagem da RNA.

	Variável	Faixa de medição (min - max)	Total de Amostras	Total de curvas
Entradas	ω [RPM]	1800 – 3000	1443	39
	P_e [kPa]	92,85 – 503,7		
	Q_l [m ³ /h]	0,23 – 63,61		
	Q_g [m ³ /h]	0,00 – 3,53		
Saídas	ΔP [kPa]	0,15 – 130,30		
	η [-]	0,00 – 0,66		

Dos testes feitos, pode-se verificar que é possível determinar o ganho de pressão (ΔP) e a eficiência (η) conhecendo os valores da vazão volumétrica de líquido (Q_l) e de gás (Q_g), a rotação (ω) e a pressão de sucção (P_e) através do tempo como proposto em (Pineda, 2016).

A seleção da estrutura e estimação do modelo foram feitas com um algoritmo de treinamento e validação cruzada baseado no método *Levenberg-Marquardt* proposto em (Hagan e Menhaj, 1994). O toolbox de redes neurais do software MATLAB foi usado neste trabalho. O resultado do algoritmo foi a configuração da rede *feedforward*, apresentando 2 camadas ocultas com 16 e 12 neurônios respectivamente.

A validação foi feita de duas formas: a primeira de forma visual e a segunda através de uma regressão linear dentre as aproximações geradas pela rede e os valores medidos. Os testes feitos com a RNA foram baseados em 3 curvas. A primeira curva tem uma rotação de 3000 RPM com pressão de sucção de 500 kPa e vazão de gás 1,1 m³/h. A segunda curva tem uma rotação de 2400 RPM com 500 kPa na sucção e 1,4 m³/h na vazão de gás. A terceira curva apresenta uma rotação de 1800 RPM com pressão de 500 kPa e vazão volumétrica de gás de 1,7 m³/h. A validação feita para a RNA pode ser verificada na Figura 1.




Figura 1: Visualização das predições da RNA em relação as curvas medidas para o ganho de pressão e eficiência no escoamento bifásico.

Após a modelagem dinâmica do sistema, o método usado para o controle da BCS foi o esquema de controle inverso-direto. O objetivo deste método é identificar o modelo inverso da planta e usá-lo como controlador. Se o controlador, que representa a dinâmica inversa da planta, é conectado em série com a planta, o resultado da multiplicação dos blocos resulta na função identidade (Zambrano, 2013).

Para obter a dinâmica inversa da planta foi projetada uma rede neuro-fuzzy (RNF) com base num sistema de inferência adaptativa neuro-fuzzy, ANFIS (ou Adaptative Neuro-Fuzzy Inference Systems em inglês) proposto por (Jang *e outros*, 1997), cuja variável de controle é a rotação. Este método usa um determinado conjunto de dados de entradas e saídas para construir um sistema de inferência difusa, cujos parâmetros são ajustados num processo de treinamento por um algoritmo “híbrido” que combina o algoritmo *backpropagation* com o método dos mínimos quadrados. Este treinamento poder ser encontrado em (Kelly *e outros*, 1994). O toolbox de redes neuro-fuzzy do software MATLAB foi usado neste trabalho para a fase de treinamento.

Assim, para obter o modelo inverso da RNA baseado na RNF, deve-se modificar o seguinte: a rotação que era uma entrada na RNA (Tabela 1) é agora a saída da RNF, e o ganho de pressão que era a saída na RNA agora é uma entrada da RNF. Além disso, para representar a dinâmica do sistema foi usado um atraso para obter dados passados e tentar prever dados futuros do sistema de controle, o que significa que a RNF tem 8 entradas.

Neste trabalho, foi usada uma técnica de classificação estatística chamada agrupamento (*clustering* em inglês). Esta técnica é usada para organizar, categorizar dados e definir a construção do modelo RNF. O *clustering* é validado da seguinte maneira: entradas semelhantes do sistema devem produzir saídas similares e esses pares de entradas e saídas semelhantes são agrupados em *clusters* na fase de treinamento. Esta técnica faz com que as regras do sistema RNF diminuam dependendo da quantidade de *clusters*, por exemplo, se existem n clusters haverá n regras (Jang *e outros*, 1997).

Da técnica explicada anteriormente, foram geradas duas regras de controle para as 8 entradas. Cada entrada do controlador estará associada a um dos dois *clusters*, e assim com cada conexão ativa, a RNF está na capacidade de tomar decisões baseadas nas duas regras geradas. Logo depois, a saída será uma combinação linear das regras RNF (Kelly *e outros*, 1994). A configuração da RNF pode ser verificada na Figura 2.




Figura 2: Esquema interno da configuração da RNF para as duas regras geradas.

Com a estrutura da RNF definida, o processo de treinamento é baseado no algoritmo “híbrido” usando os mesmos dados experimentais anteriormente mencionados. Nesses dados, três valores de rotações foram adquiridos. Observa-se que o número de dados reais é pequeno e que as técnicas de controle baseadas em RNF precisam de uma quantidade maior de dados para o treinamento (Sarangapani, 2006). Dessa forma, o conjunto de dados reais foi usado para o treinamento e validação da RNA como mostrado anteriormente e, posteriormente, a RNA foi utilizada para simular o sistema, descrevendo e generalizando a operação de uma BSC. Assim, foi obtida uma maior quantidade de amostras para o treinamento do controle. Os resultados obtidos do modelo inverso direto da RNA baseado na RNF são apresentados na Figura 3.




Figura 3: Resultados de validação do modelo e erro no treinamento para RNF.

Em seguida, com a RNF treinada e validada, esta foi colocada como controlador para fechar a malha de controle como mostrado na Figura 4, e por fim o procedimento para obter as respostas do sistema foi realizado, verificando-se os resultados através de simulações.




Figura 4: Malha fechada de controle para simulação.

Resultados e Discussão

Para a simulação do controlador neuro-fuzzy, deve-se ter a curva característica do sistema, já que a operação da bomba está associada à mesma. Logo, foi estimado um sistema que estivesse dentro das faixas dos dados para a simulação e validação do controlador. A curva do sistema foi determinada baseando-se no modelo homogêneo para escoamento bifásico. Neste modelo, as duas fases (líquido-gás) são combinadas em uma fase com propriedades médias e uma velocidade média, assumindo condição de não deslizamento.

Este sistema também depende da curva IPR (*Inflow Performance Relationship*) a qual avalia o rendimento do poço ao representar graficamente a taxa de produção do mesmo contra a pressão no fundo do poço como mostrado na Figura 5 (Thomas e outros, 2004). Nesta Figura, também pode-se verificar a curva do gradiente de pressão na coluna de produção que depende da vazão e da pressão no fundo do poço (P_{wf}).




Figura 5: Curva IPR e gradiente de pressão para poço com BCS.

Com o sistema definido, a simulação consiste em selecionar uma vazão desejada. Com essa vazão e com a curva do IPR, é calculada a pressão de fluxo no fundo de poço (P_{wf}) do sistema como mostrado na Figura 5. Logo depois são calculadas as perdas de pressão em função da vazão, para assim, calcular a pressão (referência do controlador ΔP) que a bomba precisa entregar para equilibrar o sistema. Após o equilíbrio do sistema ser determinado, é calculado o gradiente de pressão da coluna e a pressão de sucção da bomba (P_e). Por fim, com todas as variáveis consideradas que interferem no processo, é calculada a rotação (ω) que a bomba precisa para manter estas condições de operação. Porém, se a referência do sistema mudar, este procedimento é repetido iterativamente até achar o novo ponto de equilíbrio.

O controlador em malha fechada foi analisado visando 2 casos diferentes. O primeiro caso, mudando a referência na forma de uma rampa; e o segundo caso fixando uma referência. Em todos os casos, o sistema foi perturbando com bolsões de gás simulando um escoamento pistonado dentro da BCS. Na Figura 6 é apresentado um dos resultados da resposta do controlador para uma referência em rampa, e na Figura 7 é apresentado um dos resultados da resposta do controlador para referência fixa e perturbações de gás. Nas Tabelas 2 e 3 são apresentados os resultados das simulações feitas.

Na Figura 6, no gráfico da vazão pode-se verificar como a vazão gerada pela BCS na presença de gás é afetada quando o valor na referência aumenta ou diminui sujeito as perturbações. Isso pode estar relacionado com a quantidade de gás que entra na bomba. Nesse momento, o sistema de controle consegue levar a bomba a operar próximo da referência mesmo na presença de gás. Por exemplo, na Tabela 2 pode ser verificado que para uma pressão de referência de 99,97 kPa há uma vazão de gás de 2,2 m³/h, nesse ponto a resposta do sistema é estável, mas, quando está referência diminui em uma rampa até 69,89 kPa e a vazão de gás aumenta para 3,0 m³/h, na transição de um estado para o outro, a saída do sistema não é linear, mas mesmo assim, o controle leva a bomba a operar próximo da referência.

Tabela 2: Resultados dos pontos estáveis para uma referência em rampa e perturbações de gás.

Amostras	Referência [kPa]	ΔP [kPa]	Q_l [m ³ /h]	Q_g [m ³ /h]	ω [RPM]
40	56,48	54,48	33,06	1,2	2252
30	77,00	76,11	42,63	1,2	2682
30	99,97	98,14	51,32	2,2	3129
30	69,89	72,65	41,18	3,0	2612
30	92,04	92,28	49,09	2,8	2988




Figura 6: Resposta do controlador para referência em rampa e perturbações de gás.

Na Figura 7, foi simulada uma referência fixa de 83,31 kPa a cada 30 segundos de simulação, e o sistema foi perturbado com bolsões de gás que foram mudando como apresentado na Tabela 3. Nesta figura, pode-se verificar como o controlador tenta manter a saída do sistema perto da referência mudando a rotação da BCS. Quando o bolsão de gás aumenta, a rotação aumenta para compensar a perturbação. Verifica-se também que com cada aumento da vazão volumétrica de gás, a saída do sistema diminui, o que era esperado, já que quando há presença de gás no escoamento da BCS, o desempenho da mesma diminui (Biazussi, 2014). Logo, o controlador tem a capacidade de compensar este problema com um aumento da rotação.

Tabela 3: Resultados dos pontos estáveis para uma referência fixa e perturbações de gás.

Referência [kPa]	ΔP [kPa]	Q_l [m ³ /h]	Q_g [m ³ /h]	ω [RPM]
81,89	83,31	45,57	1,2	2756
81,89	81,25	44,74	2,5	2784
81,89	81,24	44,74	2,5	2784
81,89	81,10	44,71	2,2	2774
81,89	81,25	44,74	2,5	2784
81,89	85,83	46,58	3,0	2826
81,89	81,25	45,75	2,5	2784
81,89	84,01	45,85	0,8	2748
81,89	82,69	45,33	2,0	2776
81,89	81,25	44,74	2,5	2784




Figura 7: Resposta do controlador para referência fixa e perturbações de gás.

Conclusões

As RNA foram implementadas para a obtenção do modelo dinâmico da bomba, apresentado um resultado aceitável com a configuração obtida pelo método de validação cruzada e o algoritmo de *Levenberg-Marquardt*. Na validação da RNA, tanto para a saída do ganho de pressão como para a saída da eficiência, obteve-se um coeficiente de regressão linear superior a 0,99 o que significa que o aprendizado da RNA pode ser considerado bem-sucedido.

A técnica de controle RNF foi implementada baseada em dados experimentais adquiridos em uma bancada de testes para BCS. A técnica de agrupamento (*clustering*) foi útil para diminuir o número de regras do controlador criando dois *clusters* para os dados de entrada na RNF.

Nos resultados apresentados, observa-se que o controlador responde aceitavelmente bem aos sinais de referência, com erros estacionários não superiores a 3,5% em todas as simulações feitas. Na saída do controlador (rotação), as mudanças de estado ocorreram de forma suave para as simulações feitas, levando ao ponto de operação desejado sem mudanças abruptas. Na vazão, a cada mudança de estado, são apresentados picos pela presença do gás, já que na simulação, a cada mudança de estado está associada a uma vazão volumétrica de gás diferente com o fim de avaliar o método de controle.

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

BLAZUSI, J.L **Modelo de Deslizamento para Escoamento Gás-Líquido em Bomba Centrífuga Submersa Operando com Líquido de Baixa viscosidade**. Tese (Doutorado). Universidade Estadual de Campinas (UNICAMP), 2014.

HAGAN, M.T. e MENHAJ, M.B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Network**, v. 5, n. 6, 989 – 993, 1994.

JANG, J.S.R.; SUN, C.T. e MIZUTANI, E. **Neuro-Fuzzy and Soft Computing. A Computational Approach to Learning and Machine Intelligence**. Prentice Hall, 1997.

KELLY, D.; BURTIN, P. e RAHMAN, M.A. The application of a neural-fuzzy logic controller to process control. **The NASA Joint Technology Workshop on Neural Networks for Modelling and Control Fuzzy Logic**, 1994.

Nørgaard, M.; RAVN, O.; POULSEN e HANSEL, L. **Neural Networks for Modelling and Control of Dynamics Systems**. Springer, 2004.

PINEDA, Luis Fernando Ruiz. **Controle do Ponto de Operação de Bombas Centrífugas Submersas em Escoamento Líquido-Gás Usando Redes Neurais**. Dissertação (Mestrado). Universidade Estadual de Campinas (Unicamp), 2016.

SARANGAPANI, J. **Neural Network Control of Nonlinear Discrete-Time Systems**. Taylos & Francis, 2006.

THOMAS, J.E.; CORREIRA, C.A. e ROSSI, N.C.M.D. **Fundamentos em Engenharia de Petróleo**. Editora Interciência, 2004.

ZAMBRANO, William Camilo Ariza. **Controle Ativo de Vibrações Usando Redes Neurais Artificiais**. Dissertação (Mestrado). Universidade Estadual de Campinas (UNICAMP), 2013.