

ANÁLISES DE ESCOAMENTOS MULTIFÁSICOS ATRAVÉS DE REDES NEURAIS ARTIFICIAIS

HENRIQUE DE LIMA CAVALHEIRO¹; CARLOS MAURICIO RUIZ DIAZ²; MARLON MAURICIO HERNANDEZ CELY³

¹Universidade Federal de Pelotas, Centro de Engenharias CENG – henriqucavalheiro4@gmail.com

²Universidade de São Paulo – carlosruiz978@usp.br

³Universidade Federal de Pelotas, Centro de Engenharias CENG – marlon.cely@ufpel.edu.br

1. INTRODUÇÃO

O fluxo de dois líquidos imiscíveis em uma tubulação é um fenômeno associado a diversas aplicações na indústria, principalmente no que diz respeito a indústria petroleira (MONTROYA et al., 2009). Neste contexto, no processo de produção e transporte do petróleo, é comum encontrar escoamento bifásico entre água e óleo (ABDUVAYT et al., 2004).

Tendo em vista o potencial não só científico mas também industrial desta área, diversos experimentos foram conduzidos pela literatura com o intuito de fornecer dados sobre o comportamento e a interação de diferentes fluidos sob diferentes condições (IBARRA et al., 2015). Dentre estes dados está o padrão de escoamento, o qual é resultado do fluxo de duas ou mais fases, e pode ser entendido como a configuração espacial destas fases dentro da tubulação (AL-WAHAIBI et al., 2014).

O padrão de escoamento é um dado de grande importância, visto que a partir dele pode-se, por exemplo, ter um melhor controle sobre a corrosão dos tubos, que muitas vezes são de metal (CAI et al., 2012), e uma previsão confiável das variáveis do processo físico que são essenciais para a otimização do projeto de oleodutos na indústria (AL-SARKHI et al., 2017).

Neste cenário, alguns trabalhos propostos pela literatura tiveram como objetivo criar modelos preditivos para as quantidades e fenômenos de interesse do processo de escoamento (GRASSI; STRAZZA; POESIO, 2008). Uma alternativa de modelo é a utilização de redes neurais artificiais (RNA) (DASARI et al., 2013).

Existem outros estudos referentes a escoamento bifásico água-óleo utilizando técnicas de inteligência artificial baseadas em RNA. Encontra-se as análises realizadas por MERIBOUT et al. (2010) e AZIZI; AWAD; AHMADLOO (2016) em tubulações verticais e inclinadas para obter o corte e a fração volumétrica de água, enquanto no trabalho de SHIRLEY; CHAKRABARTI; DAS (2012) identificou-se padrões de escoamento em um tubo horizontal.

Assim, o objetivo deste trabalho é desenvolver e treinar uma rede neural, a partir de dados da literatura, para a análise hidrodinâmica de escoamentos multifásicos e prever um conjunto de oito padrões de escoamento em tubulações horizontais.

2. METODOLOGIA

O primeiro passo para o desenvolvimento deste trabalho foi compilar e organizar os dados numéricos obtidos na literatura em uma tabela. Este conjunto somou um total de 2156 dados de experimentos contendo: velocidade superficial da água, velocidade superficial do óleo, velocidade da mistura, concentração da água e

do óleo, diâmetro do tubo, viscosidade dinâmica do óleo e padrão de escoamento observado.

Com esta base de dados em mãos, a próxima etapa foi importar estas informações para um programa em linguagem *Python*. Com isto foi possível realizar uma análise inicial na tabela, de forma automática, utilizando os recursos fornecidos pelo *Python*, o que revelou algumas células em branco.

As células em branco representavam 27 dados nos quais não constava um valor para a viscosidade dinâmica. Então, decidiu-se inicialmente suprimir esta grandeza para todos os outros dados e utilizar o conjunto completo na construção e treinamento da primeira rede neural. Assim, esta rede contou com 5 neurônios de entrada os quais representaram a velocidade superficial do óleo, da água, da mistura, a concentração da água e o diâmetro da tubulação.

Uma segunda rede foi construída, desta vez com 6 neurônios de entrada, ou seja, a viscosidade dinâmica foi adicionada ao conjunto de entradas. Para isso, a abordagem quanto às células em branco foi a de excluir os 27 dados incompletos ao invés de remover todas as viscosidades. Nesta segunda rede foram exploradas configurações tanto de redes rasas, com apenas uma camada oculta, quanto redes profundas.

Os hiperparâmetros, que são aqueles que têm relação com o funcionamento da própria rede e não com a aplicação, como a taxa de aprendizado e número de iterações (épocas) de treinamento por exemplo (NIELSEN, 2015), têm um procedimento ainda empírico para ajustar, ou seja, não existem procedimentos exatos para obter-se os melhores resultados, mas sim diretrizes de boas práticas para tal. Por isso, o número de testes realizados até que se encontrassem resultados satisfatórios foi alto.

Além do ajuste destes parâmetros, outra medida importante foram os tratamentos estatísticos dos dados. A primeira medida foi a organização do conjunto de treinamento e do conjunto de teste da rede neural, de modo a garantir que ambos contivessem dados em todo o espectro de valores, para que o exercício de previsão fosse o de interpolação e não o de extrapolação.

A segunda medida foi normalizar a base de dados para valores entre 0 e 1, tendo em vista que utilizar os dados com seus valores originais pode causar problemas nas operações matemáticas da rede, já que a diferença de dimensão entre as variáveis físicas pode ser muito grande. Assim, transformar estas grandezas em adimensionais e ajustá-las na mesma faixa, faz com que não se criem falsos vieses por diferenças entre as escalas dos dados.

Por fim, utilizando a configuração de rede neural com a melhor acurácia e os menores erros, foi construída uma nova base de dados, na qual os pontos que foram classificados de forma equivocada pela rede foram retirados. Esta nova base de dados alcançou o tamanho de 2027 pontos e a partir dela foram treinadas novas configurações de rede neural.

3. RESULTADOS E DISCUSSÃO

O resultado do treinamento do primeiro modelo de rede neural, chegou a no máximo 78% de acurácia, e por acreditar que a falta da viscosidade dinâmica limitava este modelo, ele foi substituído por aquele com 6 neurônios de entrada.

Esta segunda rede neural apresentou uma performance consideravelmente melhor, conforme é possível observar pelas métricas estatísticas expostas na Tabela 1.

Exatidão no treinamento (%)	Exatidão no teste (%)	Exatidão na validação (%)	Exatidão total (%)	Erro Quadrático Médio	Erro Médio Absoluto	Coefficiente de Determinação (R^2)
95,0117	91,0798	89,6226	94,0817	0,6891	0,8877	0,1724

Tabela 1: Métricas da RNA

Fonte: Autor

A Figura 1 mostra uma matriz de confusão, utilizada para observar de forma quantitativa as classificações corretas e equivocadas do modelo.




Figura 1: Matriz de confusão

Fonte: Autor

4. CONCLUSÕES

Tendo obtido todos os parâmetros estatísticos anteriormente mostrados, é possível afirmar que esta técnica é viável e tem uma boa confiabilidade. Como os modelos propostos pela literatura são empíricos, pela falta de uma equação que consiga prever de forma analítica, a rede neural artificial, em conjunto com outras técnicas de inteligência artificial é uma das alternativas mais promissoras para futuros trabalhos.

A melhora de comportamento do primeiro para o segundo modelo de rede, confirma a correlação entre a viscosidade dinâmica e o padrão de escoamento apontada pela literatura.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ABDUVAYT, P. et al. **Analysis of oil-water flow tests in horizontal, hilly-terrain, and vertical pipes**. Proceedings - SPE Annual Technical Conference and Exhibition. **Anais...**2004.

AL-SARKHI, A. et al. Dimensionless oil-water stratified to non-stratified flow pattern transition. **Journal of Petroleum Science and Engineering**, v. 151, p. 284–291, 2017.

AL-WAHAIBI, T. et al. Experimental investigation on flow patterns and pressure gradient through two pipe diameters in horizontal oil-water flows. **Journal of Petroleum Science and Engineering**, v. 122, p. 266–273, 1 Out. 2014.

AZIZI, S.; AWAD, M. M.; AHMADLOO, E. Prediction of water holdup in vertical and inclined oil-water two-phase flow using artificial neural network. **International Journal of Multiphase Flow**, v. 80, p. 181–187, 2016.

CAI, J. et al. Experimental study of water wetting in oil-water two phase flow-Horizontal flow of model oil. **Chemical Engineering Science**, v. 73, p. 334–344, 7 Mai. 2012.

DASARI, A. et al. Experimental studies and probabilistic neural network prediction on flow pattern of viscous oil-water flow through a circular horizontal pipe. **Industrial and Engineering Chemistry Research**, v. 52, n. 23, p. 7975–7985, 12 Jun. 2013.

GRASSI, B.; STRAZZA, D.; POESIO, P. Experimental validation of theoretical models in two-phase high-viscosity ratio liquid-liquid flows in horizontal and slightly inclined pipes. **International Journal of Multiphase Flow**, v. 34, n. 10, p. 950–965, Out. 2008.

IBARRA, R. et al. **Towards a universal dimensionless map of flow regime transitions in horizontal liquid-liquid flows**. 11th International Conference on Heat Transfer, Fluid Mechanics and Thermodynamics. **Anais...**2015. Disponível em: <https://www.researchgate.net/publication/283498693_Towards_a_Universal_Dimensionless_Map_of_Flow_Regime_Transitions_in_Horizontal_Liquid-Liquid_Flows>

MERIBOUT, M. et al. Integration of impedance measurements with acoustic measurements for accurate two phase flow metering in case of high water-cut. **Flow Measurement and Instrumentation**, v. 21, n. 1, p. 8–19, 2010.

MONTOYA, G. et al. Determinación de altura de fase y hold up para flujo bifásico líquido-líquido en tuberías horizontales por medio de procesamiento de imágenes. **Memorias del congreso ASME USB 2009**, p. 1–10, 2009.

NIELSEN, M. A. **Neural Networks and Deep Learning**. San Francisco, CA, USA: Determination press, 2015.

SHIRLEY, R.; CHAKRABARTI, D. P.; DAS, G. Artificial Neural Networks in Liquid-Liquid Two-Phase Flow. **Chemical Engineering Communications**, v. 199, n. 12, p. 1520–1542, 2012.