

CAPÍTULO 1

REDE NEURAL ARTIFICIAL E MEDAÇÃO DE FLUXO MULTIFÁSICO

César Marques Salgado

William Luna Salgado

Roos Sophia de Freitas Dam

Claudio de Carvalho Conti

O fluxo multifásico é amplamente observado em diversas áreas da engenharia e da ciência. Na indústria de petróleo e gás, em particular, há uma crescente demanda por técnicas precisas de medição das vazões de água, gás e óleo. Este livro foca na medição do fluxo multifásico de hidrocarbonetos, abordando tópicos, como fluxo em meios porosos [1, 2, 3, 4], o movimento de fluidos em poços [5, 6, 7], e transporte em tubulações [8, 9, 10]. Os fluidos, definidos como materiais que se deformam facilmente e se ajustam às condições em que estão inseridos, apresentam características distintas de compressibilidade. Embora todos os fluidos sejam tecnicamente compressíveis, na prática, gases são tratados como

compressíveis e líquidos como incompressíveis devido à insignificante variação de densidade dos líquidos sob condições normais.

A determinação das propriedades dos fluidos em fluxo monofásico é geralmente direta. No entanto, essa tarefa se torna mais complexa para gases, devido à sua natureza compressível, e ainda mais desafiadora para fluxos multifásicos, em que as propriedades da mistura não podem ser obtidas simplesmente pela soma das características individuais dos componentes. Além disso, em fluxos multifásicos pode ocorrer transferência de massa entre as fases [11]. A medição de vazões em fluxos multifásicos pode ser realizada por separação de fases ou pelo uso de medidores específicos. O método convencional envolve separadores, que dependem das diferenças físicas entre os componentes do fluxo. Em separadores bifásicos, gás e líquido se separam devido às diferenças de densidade e ao tempo de residência dentro do equipamento. Em separadores trifásicos, além do gás, a água e o óleo também se separam devido à imiscibilidade e às diferenças de

densidade e viscosidade. Uma vez separadas, as fases são medidas utilizando medidores monofásicos¹. [12] Apesar de amplamente utilizados, separadores enfrentam desafios, como dificuldades na separação de emulsões e espuma, falhas na manutenção dos medidores e problemas na separação de microbolhas em líquidos viscosos. Além disso, não fornecem informações sobre o regime de fluxo ou a fração de gás/vapor (FVG). Por esse motivo, métodos alternativos, como medidores de fluxo multifásico vêm ganhando destaque [13]. Os medidores de fluxo multifásico, uma tecnologia mais recente, operam medindo a vazão total da mistura, determinando as frações das fases individuais e calculando as vazões de cada fase com base nessas informações. Para aumentar a precisão, esses medidores multifásicos frequentemente combinam diferentes tecnologias e possuem designs variados dependendo do fabricante [14, 15, 16].

Redes neurais artificiais têm se mostrado ferramentas poderosas para a classificação de regimes de fluxo e a previsão das vazões das fases individuais [17, 18, 19]. Essas redes neurais são amplamente utilizadas na determinação de parâmetros de fluxo multifásico, como vazão de óleo e gás, identificação de padrões de fluxo e estimativa de fração volumétrica de gás (FVG) ou de líquido (*holdup*). Para isso, as entradas da rede neural artificial são relacionadas às vazões e aos regimes de fluxo, sendo alimentadas por dados de sensores que podem ser categorizados em cinco grupos principais:

- I. Sinais de detectores de radiação (especialmente energia de raios gama);
- II. Sinais de impedância elétrica;
- III. Sinais ultrassônicos;
- IV. Sinais de pressão;
- V. Sinais provenientes de propriedades físicas dos fluidos em fluxo (como densidade, temperatura e velocidade).

Nas seções seguintes deste capítulo, serão detalhadas as aplicações de redes neurais artificiais em medições de fluxo multifásico. A organização segue os parâmetros a serem medidos (regime de fluxo, fração de vazio e vazão) e os métodos utilizados (radioativos, ultrassônicos, elétricos, baseados em pressão ou propriedades do fluxo).

REGIMES DE FLUXO

Em tubulações verticais ou ligeiramente inclinadas, as misturas de gás e líquido frequentemente apresentam regimes de fluxo, como anular, estratificado e bolhas. Em tubulações horizontais, além desses regimes, podem ocorrer fluxos ondulados ou estratificados. Outros regimes, como *plug*, disperso e transição, também são relevantes, especialmente na análise de problemas em zonas de transição.

1. *Medidores:* i) Pressão Diferencial: Mede a velocidade média do fluido com base na perda de pressão provocada pela redução no tópico de passagem; ii) Turbina: Mede a vazão a partir da rotação de uma turbina, que é proporcional ao movimento causado pelo escoamento do fluido; iii) Placa: Determina a força exercida pelo fluido em uma placa disposta transversalmente ao escoamento, sendo esta força proporcional à sua velocidade.

Durante o monitoramento de fluxos multifásicos em tubulações, os medidores produzem sinais complexos, cuja interpretação é desafiadora devido à natureza não linear e multidimensional desses dados. Métodos tradicionais de processamento de sinal frequentemente enfrentam limitações para analisar adequadamente esses sinais. Entre os métodos já utilizados estão: Função de Densidade de Probabilidade, Espectros de Potência, *Wavelet*, *Hilbert-Huang*, *Gabor*, Dimensões Fractais e séries de *Markov* [20, 21, 22, 23]. Adicionalmente, técnicas, como a Transformada Discreta de Wavelet (DWT - *Discrete Wavelet Transform*) e Densidade Espectral de Potência (PSD - *Power Spectral Density*) também têm sido utilizadas por Hernandez et al., (2006) [24].

Além desses, outros métodos baseados em impedância elétrica (capacitância), técnicas nucleares (radiação gama e nêutrons), sinais de pressão e atenuação acústica têm sido aplicados para estimar parâmetros do fluxo multifásico. Contudo, esses métodos exigem uma identificação precisa de padrões de fluxo, o que motivou o uso crescente de técnicas de inteligência artificial para essa finalidade. As redes neurais artificiais (RNA) têm se mostrado promissoras na classificação de regimes de fluxo, sendo utilizadas em diferentes abordagens, como:

- I. Perceptron de múltiplas camadas com retropropagação, *nearest neighbor*, e *classification tree* [25];
- II. *Neuro-fuzzy* [26];
- III. Redes neurais auto-organizáveis [27];
- IV. Redes neurais probabilísticas [24];
- V. Redes neurais profundas [28];
- VI. Redes neurais convolucionais [29, 30, 31, 32];
- VII. Redes neurais LSTM [33];
- VIII. Redes neurais de funções de base radial [34, 35, 36].

A identificação do regime de fluxo pode ser realizada por meio da análise de sinais elétricos, considerando o fluido em escoamento como um condutor elétrico. Sensores baseados em capacidade e resistência elétrica são amplamente utilizados para estimar parâmetros do fluxo [37, 38]. Esses sensores capturam sinais que representam a resistência elétrica do fluido, permitindo a determinação de propriedades fundamentais da mistura, como capacidade e condutância entre as fases líquida e gasosa [39]. Situações que envolvem mudanças de fase, como transição entre óleo e água, exigem o uso de métodos alternativos, devido às diferenças nas propriedades dielétricas das fases. Além disso, variações de temperatura podem comprometer a precisão das medições elétricas, tornando indispensável o isolamento térmico da tubulação para minimizar interferências e assegurar resultados mais confiáveis [40, 41].

Uma ampla gama de parâmetros do sistema pode ser utilizada para a classificação dos regimes de fluxo. Entre eles, destacam-se a densidade, viscosidade, diâmetro do tubo, ângulo de inclinação, temperatura, pressão, gradiente de pressão, velocidade superficial dos fluidos, números de *Reynolds*, *Weber* e *Froude*. Outros fatores, como vibração induzida e tensão superficial, também desempenham um papel relevante. Esses parâmetros podem ser utilizados como variáveis de entrada em redes neurais artificiais, permitindo capturar os fenômenos hidrodinâmicos associados às variações nas propriedades do fluido. Essa abordagem é particularmente eficaz para modelar as complexas interações presentes nos regimes de fluxo multifásico [28, 42, 43].

Outra abordagem é o uso de sinais de pressão. A passagem de gás e líquido induz flutuações de pressão, uma característica atrativa para a caracterização de padrões de fluxo. Sensores, como transdutores de pressão diferencial e medidores de fluxo de vórtice são econômicos, duráveis, e adequados para aplicações industriais [44]. Estudos demonstram a eficácia da análise da densidade espectral de potência e função de densidade de probabilidade de flutuações de pressão para identificar padrões em fluxos bifásicos de gás/líquido [45, 46].

Técnicas ultrassônicas também têm destaque, sendo não invasivas, robustas e relativamente econômicas. Baseiam-se na atenuação de pulsos ultrassônicos na interface parede-líquido e no tempo de retorno do eco, permitindo a detecção de interfaces gás-líquido [47]. Sensores Doppler ultrassônicos são amplamente aplicados na medição não invasiva de velocidade de fluxo. No entanto, a calibração prévia do sinal ainda é uma limitação significativa, podendo ser mitigada com o uso de redes neurais artificiais.

Por fim, técnicas nucleares, como a densitometria gama, são amplamente utilizadas. Baseadas em princípios de atenuação e espalhamento de radiação, essas técnicas permitem calcular frações volumétricas e identificar os regimes de fluxo a partir de taxas de contagem medidas nos detectores [19, 48, 49, 50]. Estudos recentes destacam o uso de radioatividade na análise de fluxos multifásicos em diversas configurações de medição [51, 52, 53, 54, 55, 56].

As RNAs desempenham um papel fundamental na modelagem de relações complexas entre variáveis de entrada e saída, especialmente na identificação automática de padrões de fluxo. Sua capacidade de capturar comportamentos não lineares e dependências cruzadas entre variáveis reforça seu potencial em aplicações industriais e acadêmicas.

VAZÃO

Medidores de fluxo multifásico desempenham um papel crucial em diversas etapas da produção de petróleo, fornecendo dados rápidos e precisos para testes dos poços. Esses dispositivos são particularmente úteis em ambientes remotos ou não tripulados, em instalações de superfície (*topside*) onde o espaço é limitado, e em implantações submarinas. Entre os principais parâmetros medidos estão as vazões das diferentes fases: óleo, gás e água.

A estimativa das vazões de óleo, no entanto, apresenta desafios significativos, especialmente em situações em que a medição direta não é possível. Nesses casos, engenheiros de petróleo frequentemente recorrem a correlações empíricas, que podem introduzir erros consideráveis e levar a resultados imprecisos.

Como alternativa, redes neurais artificiais (RNAs) têm sido amplamente aplicadas na análise de sinais elétricos e acústicos de fluidos captados por transdutores ultrassônicos [57]. Esses sinais, integrados a modelos físicos de escoamento multifásico, medições de pressão diferencial de tubos Venturi e sensores de pressão, possibilitam determinar com alta precisão a velocidade e a densidade de cada fase [58]. Estudos em poços *offshore*, como os localizados no North West Java e no norte do Golfo Pérsico, no Irã, demonstraram a eficácia das RNAs, alcançando erros relativos inferiores a 10% em 90% das medições [59, 60].

Nesse método, dados de pressão e temperatura dos oleodutos são usados como entradas para a RNA, enquanto a vazão de óleo é a variável de saída. A vazão multifásica depende diretamente das frações volumétricas, da velocidade superficial de cada fase e do regime de fluxo.

Os sensores Venturi são amplamente utilizados para medir a velocidade do fluxo multifásico. Nesses dispositivos, a vazão mássica é correlacionada à diferença de pressão entre duas seções monitoradas, enquanto a velocidade é estimada por técnicas de processamento de sinais, como a Correlação Cruzada (*Cross-Correlation*). Para isso, dois sensores idênticos são posicionados ao longo do tubo, e o padrão de sinal capturado pelo primeiro é replicado pelo segundo após um intervalo de tempo, conhecido como tempo de trânsito.

Medidores de fluxo multifásico oferecem a vantagem de medir diretamente as frações individuais de cada fase em uma tubulação, eliminando a necessidade de separação física ou amostragem dos fluidos.

Outra solução para a medição de vazões envolve o uso de programas de simulação de processos e técnicas de estimativa de parâmetros. Esses sistemas permitem o desenvolvimento de soluções de medição multifásica baseadas em dados de pressão e temperatura no ponto de chegada do oleoduto, dispensando hipóteses sobre o estado do fluido. As variáveis utilizadas incluem: velocidades superficiais de líquido e gás, temperatura, pressão, propriedades dos fluidos (viscosidade, tensão superficial e densidade), além de características do tubo (diâmetro e inclinação).

Os Métodos radioativos, como a densitometria gama, são amplamente utilizados para determinar frações de volume em sistemas multifásicos óleo-água-gás [19]. Esse método baseia-se nos princípios de atenuação e espalhamento de raios gama, utilizando uma geometria específica que consiste em uma fonte de radiação gama e detectores estrategicamente posicionados para captar as interações da radiação com as diferentes fases do fluxo.

Adicionalmente, sensores elétricos têm se mostrado eficientes na realização de medições tomográficas de capacidade elétrica possibilitando a análise detalhada da composição dos fluidos em processos de fluxo^[61]. Por outro lado, os sensores ultrassônicos destacam-se na quantificação do *holdup*² em fluxos bifásicos água/óleo, utilizando princípios de difusão ultrassônica para avaliar as características das fases presentes no escoamento^[62].

Essas abordagens complementares oferecem soluções robustas para a caracterização de sistemas multifásicos, atendendo às demandas da indústria de óleo e gás com precisão e versatilidade.

CONCLUSÃO

Neste capítulo, foram tratados temas relevantes da aplicação de RNAs na análise de parâmetros de fluxo multifásico. Foram abordados tópicos fundamentais, como a classificação do regime de fluxo, a investigação da fração de volume das fases e, por fim, a determinação da vazão das diferentes fases.

Diversos parâmetros de fluxo, incluindo pressão, temperatura, velocidade e viscosidade, foram destacados como variáveis frequentemente utilizadas no treinamento de RNAs. A literatura apresenta uma ampla gama de pesquisas sobre a medição de fluxo multifásico utilizando essas redes, empregando técnicas baseadas em ondas ultrassônicas, sinais elétricos e procedimentos com radiação gama. Os resultados indicam que RNAs bem desenvolvidas, especialmente aquelas com algoritmo de retropropagação de erro e configurações de uma ou duas camadas ocultas, são eficazes na determinação de parâmetros de fluxo, contribuindo para um aumento significativo na precisão dos resultados.

Contudo, foi enfatizada a importância de dispor de um volume expressivo de dados para que as RNAs possam ser aplicadas com eficácia a uma ampla variedade de cenários. Esses cenários incluem variáveis, como diâmetro dos tubos, viscosidades dos fluidos, densidades e razão gás-líquido. A identificação precisa dos padrões de fluxo em sistemas multifásicos continua sendo um desafio. No entanto, com dados adequados e o uso de técnicas robustas de normalização e escalonamento, a tarefa pode ser realizada com elevada precisão.

As RNAs possuem grande potencial de aplicação em várias indústrias, como a caracterização e simulação de reservatórios, recuperação avançada de petróleo, testes de poços, mecânica de rochas, limpeza de poços e o estudo do fluxo de fluidos em meios porosos. Apesar do potencial promissor dessas áreas, este capítulo não abordou tais tópicos em profundidade, visando evitar dispersão e manter o foco da discussão.

2. *Holdup do líquido* é definido como a razão entre o volume de um segmento de tubo ocupado por líquido e o volume total deste segmento.

Por fim, embora as técnicas de inteligência artificial, como as RNAs, tenham contribuído significativamente para o aprimoramento na obtenção de parâmetros multifásicos, é essencial continuar avaliando a eficácia dessas redes frente às variações nas propriedades dos fluidos produzidos, como petróleo e gás. Além disso, seria oportuno ampliar as discussões futuras para outras abordagens de inteligência artificial, como algoritmos genéticos, que podem complementar as RNAs na solução de problemas complexos e multidimensionais.

REFERÊNCIAS

- [1] Tabzar, A.; Fathinasab, M.; Salehi, A.; Bahrami, B. Multiphase flow modeling of asphaltene precipitation and deposition. *Oil & Gas Science and Technology–Revue d'IFP Energies nouvelles*, v. 73, n. 3, p. 51, 2018.
- [2] Zhao, B.; MacMinn, C.W.; Primkulov, B.K.; Chen, Y.; Valocchi, A.J.; Zhao, J.; Kang, Q.; Bruning, K.; McClure, J.E.; Miller, C.T.; Fakhari, A.; Bolster, D.; Hiller, T.; Brinkmann, M.; Cueto-Felgueroso, L.; Co-gswell, D.A.; Verma, R.; Prodanović, M.; Maes, J.; Geiger, S.; Vassvik, M.; Hansen, A.; Segre, E.; Holtzman, R.; Yang, Z.; Yuan, C.; Chareyre, B.; Juanes, R. Comprehensive comparison of pore-scale models for multiphase flow in porous media. In: *Proceedings of the National Academy of Sciences*, v. 116, n. 28, p.13799-13806, 2019.
- [3] Haghi, A.H.; Chalaturnyk, R.; Talman, S. Stress-Dependent Pore Deformation Effects on Multiphase Flow Properties of Porous Media. *Scientific reports*, v. 9, n. 1, p. 1-10, 2019.
- [4] Bakhshian, S.; Hosseini, S.A.; Shokri, N. Pore-scale characteristics of multiphase flow in heterogeneous porous media using the lattice Boltzmann method. *Scientific reports*, v. 9, n. 1, 2019. Disponível em: <https://doi.org/10.1038/s41598-019-39741-x>
- [5] Al-Rbeawi, S. Pseudo-steady state inflow performance relationship of reservoirs undergoing multiphase flow and different wellbore conditions. *Journal of Natural Gas Science and Engineering*, v. 68, 2019. Disponível em: <https://doi.org/10.1016/j.jngse.2019.102912>
- [6] Hou, Z.; Yan, T.; Li, Z.; Feng, J.; Sun, S.; Yuan, Y. Temperature prediction of two phase flow in wellbore using modified heat transfer model: An experimental analysis. *Applied Thermal Engineering*, v. 149, p. 54-61, 2019.
- [7] Tariq, Z.; Mahmoud, M.; Abdulraheem, A. Real-time prognosis of flowing bottom-hole pressure in a vertical well for a multiphase flow using computational intelligence techniques. *Journal of Petroleum Exploration and Production Technology*, p. 1-18, 2019.
- [8] Chi, Y.; Sarica, C.; Daraboina, N. Experimental investigation of two-phase gas-oil stratified flow wax deposition in pipeline. *Fuel*, v. 247, p. 113-125, 2019.
- [9] Leporini, M.; Marchetti, B.; Corvaro, F.; di Giovine, G.; Polonara, F.; Terenzi, A. Sand transport in multiphase flow mixtures in a horizontal pipeline: An experimental investigation. *Petroleum*, v. 5, n. 2, p. 161-170, 2019.
- [10] Sultan, R.A.; Rahman, M.A.; Rushd, S.; Zendehboudi, S.; Kelessidis, V.C. Validation of CFD model of multiphase flow through pipeline and annular geometries. *Particulate Science and Technology*, v. 37, n. 6, p. 685-697, 2019.

- [11] Bruvik, E.; Hjertaker, B. Liquid characterization and measurement of fluid properties for reduced uncertainty in multiphase flow area fraction measurements. *Flow Measurement and Instrumentation*, v. 47, p. 10-18, 2016.
- [12] Seo, N.; Kharoua, N.; Khezzar, L.; Alshehhi, M. Multiphase Flow Simulation of In-Line Gas-Liquid Separator for Multiphase Metering. In: *Fluids Engineering Division Summer Meeting*. The American Society of Mechanical Engineers, 2019. Disponível em: <https://doi.org/10.1115/AJKFluids2019-4802>.
- [13] Dang, W.; Gao, Z.; Hou, L.; Lv, D.; Qiu, S.; Chen, G. A novel deep learning framework for industrial multiphase flow characterization. *IEEE Transactions on Industrial Informatics*, v. 15, n. 11, p. 5954-5962, 2019.
- [14] Falcone, G.; Hewitt, G.; Alimonti, C. *Multiphase flow metering: Principles and applications*. 2009: Elsevier.
- [15] Michaelides, E.; Crowe, C.T.; Schwarzkopf, J.D. *Multiphase flow handbook*. 2016: CRC Press.
- [16] Ma, L.; McCann, D.; Hunt, A. Combining magnetic induction tomography and electromagnetic velocity tomography for water continuous multiphase flows. *IEEE Sensors Journal*, v. 17, n. 24, p. 8271-8281, 2017.
- [17] Sheppard, C.; Russell, D. The application of artificial neural networks to non-intrusive multi-phase metering. *Control Engineering Practice*, v. 1, n. 2, p. 299-304, 1993.
- [18] Salgado, C.M.; Brandão, L.E.B.; Schirru, R.; Pereira, C.M.N.A.; Silva, A.X.; Ramos, R. Prediction of volume fractions in three-phase flows using nuclear technique and artificial neural network. *Applied Radiation and Isotopes*, v. 67, p. 1812-1818, 2009.
- [19] Salgado, C.M.; Pereira, C.M.N.A.; Schirru, R.; Brandão, L.E. Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, v. 52, p. 555-562, 2010.
- [20] Ding, H.; Huang, Z.; Song, Z.; Yan, Y. Hilbert–Huang transform based signal analysis for the characterization of gas–liquid two-phase flow. *Flow measurement and instrumentation*, v. 18, n. 1, p. 37-46, 2007.
- [21] Pai, M.G.; Subramaniam, S. A comprehensive probability density function formalism for multiphase flows. *Journal of Fluid Mechanics*, v. 628, p. 181-228, 2009.
- [22] Hu, L.-D.; Jin, N.-D.; Gao, Z.-K. Characterization of horizontal gas–liquid two-phase flow using Markov model-based complex network. *International Journal of Modern Physics C*, v. 24, n. 5, 2013. Disponível em: <https://doi.org/10.1142/S0129183113500289>
- [23] Zhang, K.; Hou, Y.D.; Tian, W.X.; Zhang, Y.P.; Su, G.H.; Qiu, S.Z. Theoretical prediction of single bubble motion in vertically upward two-phase flow across inclined tube bundles. *Annals of Nuclear Energy*, v. 128, p. 422-432, 2019.
- [24] Hernandez, L.; Juliá, J.E.; Chiva, S.; Paranjape, S.; Ishii, M. Fast classification of two-phase flow regimes based on conductivity signals and artificial neural networks. *Measurement Science and Technology*, v. 17, n. 6, 2006. Disponível em: <https://doi.org/10.1088/0957-0233/17/6/032>

- [25] Ozbayoglu, A.M.; Yuksel, H.E. Analysis of gas–liquid behavior in eccentric horizontal annuli with image processing and artificial intelligence techniques. *Journal of petroleum science and engineering*, v. 81, p. 31-40, 2012.
- [26] El-Sebakhy, E.A. Flow regimes identification and liquid-holdup prediction in horizontal multiphase flow based on neuro-fuzzy inference systems. *Mathematics and Computers in Simulation*, v. 80, n. 9, p. 1854-1866, 2010.
- [27] Mi, Y.; Ishii, M.; Tsoukalas, L. Flow regime identification methodology with neural networks and two-phase flow models. *Nuclear engineering and design*, v. 204, n. 1-3, p. 87-100, 2001.
- [28] Lin, Z.; Liu, X.; Lao, L.; Liu, H. Prediction of two-phase flow patterns in upward inclined pipes via deep learning. *Energy*, v. 210, 2020. <https://doi.org/10.1016/j.energy.2020.118541>
- [29] Kuang, B.; Nnabuife, S.G.; Sun, S.; Whidborne, J.F.; Rana, Z.A. Gas-liquid flow regimes identification using non-intrusive Doppler ultrasonic sensor and convolutional recurrent neural networks in an s-shaped riser. *Digital Chemical Engineering*, v. 2, 2022. Disponível em: <https://doi.org/10.1016/j.dche.2022.100012>
- [30] Khan, U.; Pao, W.; Sallih, N.; Hassan, F. Flow Regime Identification in Gas-Liquid Two-Phase Flow in Horizontal Pipe by Deep Learning. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, v. 27, n. 1, p. 86-91, 2022.
- [31] Nnabuife, S.G.; Kuang, B.; Whidborne, J.F.; Ran, A. Development of gas-liquid flow regimes identification using a noninvasive ultrasonic sensor, belt-shape features, and convolutional neural network in an S-shaped riser. *IEEE Transactions on Cybernetics*, v. 53, 1, p. 3-17, 2021.
- [32] Vahabi, N. *Machine learning algorithms for analysis of oil, gas and water well acoustic datasets*. UCL (University College London), 2019.
- [33] Boorboor, S.; Feghhi, S.; Jafari, H. Development of an intelligent dual-beam gamma densitometer for real-time recognition of two-phase flow regime in horizontal pipe. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, v. 1054, 2023. Disponível em: <https://doi.org/10.1016/j.nima.2023.168412>
- [34] Jia, Z.-H.; Niu, G.; Wang, J. Flow regime identification in two-phase flow by using neural network. *Journal of Chemical Engineering of Chinese Universities*, v. 19, n. 3, p. 368-372, 2005.
- [35] Liang, F.; Hang, Y.; Yu, H.; Gao, J. Identification of gas-liquid two-phase flow patterns in a horizontal pipe based on ultrasonic echoes and RBF neural network. *Flow Measurement and Instrumentation*, v. 79, 2021. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2021.101960>
- [36] Rosa, E.S.; Salgado, R.M.; Ohishi, T.; Mastelari, N. Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas–liquid flows. *International Journal of Multiphase Flow*, v. 36, n. 9, p. 738-754, 2010.
- [37] Ghosh, S.; Pratihar, D.K.; Maiti, B.; Das, P.K. Identification of flow regimes using conductivity probe signals and neural networks for counter-current gas–liquid two-phase flow. *Chemical Engineering Science*, v. 84, p. 417-436, 2012.
- [38] Roman, A.J.; Kreitzer, P.J.; Ervin, J.S.; Hanchak, M.S.; Byrd, L.W. Flow pattern identification of horizontal two-phase refrigerant flow using neural networks. *International Communications in Heat and Mass Transfer*, v. 71, p. 254-264, 2016.

- [39] Tsoukalas, L.H.; Ishii, M.; Mi, Y. A Neurofuzzy methodology for impedance-based multiphase flow identification. *Engineering Applications of Artificial Intelligence*, v. 10, n. 6, p. 545–555, 1998.
- [40] Mi, Y.; Tsoukalas, L.; Ishii, M. Application of multiple self-organizing neural networks: Flow pattern classification. *Transactions of the American Nuclear Society*, v. 77, p. 114-116, 1997.
- [41] Mi, Y.; Ishii, M.; Tsoukalas, L. Vertical two-phase flow identification using advanced instrumentation and neural networks. *Nuclear engineering and design*, v. 184, n. 2-3, p. 409-420, 1998.
- [42] Al-Dogail, A.; Gajbhiye, R.; AlNajim, A.; AlNaser, M. Dimensionless artificial intelligence-based model for multiphase flow pattern recognition in horizontal pipe. *SPE Production & Operations*, v. 37, n. 2, p. 244-262, 2022.
- [43] AlSaif, A.; Al-Sarkhi, A.; Ismaila, K.; Abdulkadir, M. Road map to develop an artificial neural network to predict two-phase flow regime in inclined pipes. *Journal of Petroleum Science and Engineering*, v. 217, 2022. <https://doi.org/10.1016/j.petrol.2022.110877>
- [44] Drahoš, J.; Zahradník, J.; Punčochář, M.; Fialová, M.; Bradka, F. Effect of operating conditions on the characteristics of pressure fluctuations in a bubble column. *Chemical Engineering and Processing: Process Intensification*, v. 29, n. 2, p. 107-115, 1991.
- [45] Franca, F.; Acikgoz, M.; Lahey, R.T.; Clausse, A. The use of fractal techniques for flow regime identification. *International Journal of Multiphase Flow*, v. 17, n. 4, p. 545-552, 1991.
- [46] Shim, W.J.; Jo, C.H. Analysis of pressure fluctuations in two-phase vertical flow in annulus. *Journal of Industrial and Engineering Chemistry*, v. 6, n. 3, p. 167-173, 2000.
- [47] Kuang, B.; Nnabuife, S.; Sun, S.; Whidborne, J. Gas-liquid flow regimes identification using non-intrusive Doppler ultrasonic sensor and convolutional recurrent neural networks in an s-shaped riser. *Digital Chemical Engineering*, v. 2, 2022. Disponível em: <https://doi:10.1016/j.dche.2022.100012>
- [48] Jeshvaghani, P.A.; Khorsandi, M.; Panahi, R. Flow regime identification and gas volume fraction prediction in two-phase flows using a simple gamma-ray gauge combined with parallel artificial neural networks. *Flow Measurement and Instrumentation*, 86, 2022. Disponível em: <https://doi.org/10.1016/j.flowmeasinst.2022.102190>
- [49] Zhu, J.H.; Munjal, R.; Sivaram, A.; Paul, S.R.; Tian, J.; Jolivet, G. Flow regime detection using gamma-ray-based multiphase flowmeter: A machine learning approach. *International Journal of Computational Methods and Experimental Measurements*, v. 10, n. 1, p. 26-37, 2022.
- [50] Boorboor, S.; Feghhi, S.; Jafari, H. Design and construction of an LSTM-powered high sampling rate dual-beam gamma densitometer for real-time measurement of the two-phase flow void fraction. *Nuclear Engineering and Design*, 411, 2023. Disponível em: <https://doi.org/10.1016/j.nucengdes.2023.112444>
- [51] Hosseini, S.; Taylan, O.; Abusurrah, M.; Akilan, T.; Nazemi, E.; Eftekhari-Zadeh, E.; Bano, F.; Roshani, G.H. Application of wavelet feature extraction and artificial neural networks for improving the performance of gas–liquid two-phase flow meters used in oil and petrochemical industries. *Polymers*, v. 13, n. 21, 2021. Disponível em: <https://doi.org/10.3390/polym13213647>
- [52] Sattari, M. A.; Roshani, G. H.; Hanus, R. Improving the structure of two phase flow meter using feature extraction and GMDH neural network. *Radiation Physics and Chemistry*, v. 171, 2020. Disponível em: <https://doi.org/10.1016/j.radphyschem.2020.108725>

- [53] Salgado, W.L.; Dam, R.S.F.; Salgado, C.M. Optimization of a flow regime identification system and prediction of volume fractions in three-phase systems using gamma-rays and artificial neural network. *Applied Radiation and Isotopes*, 169, 2021. Disponível em: <https://doi.org/10.1016/j.apradiso.2020.109552>
- [54] Mayet, A.M.; Ilyinichna, G.E.; Fouladnia, F.; Sh.Daoud, M.; Ilyas, V.P.T.; Shukla, N.K.; Habeeb, M.S.; Alhashim, H.H. An artificial neural network and a combined capacitive sensor for measuring the void fraction independent of temperature and pressure changes for a two- phase homogeneous fluid. *Flow Measurement and Instrumentation*, v. 93, 2023. <https://doi.org/10.1016/j.flowmeasinst.2023.102406>.pp. 102406
- [55] Chen, T.-C.; Taylan, O.; Alizadeh, S.M.; Yilmaz, M.T.; Nazemi, E.; Balubaid, M.; Roshani, G.H.; Karaboga, D. Investigation of Time-Domain Feature Selection and GMDH Neural Network Application for Determination of Volume Percentages in X-Ray-Based Two-Phase Flow Meters. *MAPAN*, v. 38, n. 1, p. 119-131, 2023.
- [56] Iliyasu, A.M.; Benselama, A.S.; Bagaudinovna, D.K.; Roshani, G.H.; Salama A.S. Using Particle Swarm Optimization and Artificial Intelligence to Select the Appropriate Characteristics to Determine Volume Fraction in Two-Phase Flows. *Fractal and Fractional*, v. 7, n. 4, 2023. Disponível em: <https://doi.org/10.3390/fractfrac7040283>
- [57] Roy, B.K. A practically validated intelligent calibration technique using optimized ANN for ultrasonic flow meter. *International Journal on Electrical Engineering and Informatics*, v. 7, n. 3, p. 379-393, 2015.
- [58] Shaban, H.; Tavoularis, S. Measurement of gas and liquid flow rates in two-phase pipe flows by the application of machine learning techniques to differential pressure signals. *International journal of multiphase flow*, v. 67, p. 106-117, 2014.
- [59] Hasanzadeh, M.; Bernetti, S. Predicting oil flow rate due to multiphase flow meter by using an artificial neural network. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, v. 37, n. 8, p. 840-845, 2015.
- [60] Al-Qutami, T.A.; Ibrahim, R.; Ismail, I.; Ishak, M.Z., 2017. Development of soft sensor to estimate multiphase flow rates using neural networks and early stopping. *International Journal on Smart Sensing & Intelligent Systems*, 10(1), p. 1-24.
- [61] Nazemi, E.; Feghhi, S.A.H.; Roshani, G.H. Void fraction prediction in two-phase flows independent of the liquid phase density changes. *Radiation measurements*, v. 68, p. 49-54, 2014.
- [62] Liu, J.; Wang, A. Application of RBF neural network to ultrasonic holdup measurement for water-oil two phase flow. Dynamics of Continuous, Discrete and Impulsive Systems Series B: Applications and Algorithms. In: Conference: International Conference on Complex Systems and Applications, v. 13, 2006.