

## IDENTIFICAÇÃO AUTOMÁTICA DOS PADRÕES DE ESCOAMENTO BIFÁSICO A PARTIR DE IMAGENS UTILIZANDO APRENDIZADO DE MÁQUINA

NATÁSSIA SIQUEIRA<sup>1</sup>; JOÃO BEZERRA<sup>2</sup>; LETÍCIA SOARES<sup>2</sup>;  
JAIRO RAMALHO<sup>2</sup>, MARLON CELY<sup>2</sup>; DANIEL PALOMINO<sup>3</sup>

<sup>1</sup>Universidade Federal de Pelotas – nrmsiqueira@inf.ufpel.edu.br

<sup>2</sup> Universidade Federal de Pelotas – jimbezerra@inf.ufpel.edu.br, math2020.01@gmail.com, marlon.cely@ufpel.edu.br

<sup>2</sup> Universidade Federal de Pelotas – jairo.ramalho@ufpel.edu.br

<sup>3</sup> Universidade Federal de Pelotas – dpalomino@inf.ufpel.edu.br

### 1. INTRODUÇÃO


Os escoamentos bifásicos gás-líquido são onipresentes em aplicações industriais críticas, abrangendo a indústria química, petrolífera e energética. A intrincada dinâmica interfacial que rege estes sistemas multifásicos determina diretamente a otimização do processo, a segurança operacional e a confiabilidade do equipamento (ZHANG *et al.*, 2023; TAZIKEH *et al.*, 2024). Para refinar as simulações de dinâmica de fluidos computacional (CFD), melhorar os protocolos de monitorização em tempo real e garantir um desempenho operacional máximo é necessário procedimentos que identifiquem de forma precisa estes tipos de padrões de escoamento (CHOWDHURY; COLOMBO, 2024).

Entretanto, um dos principais obstáculos nessa área é a escassez de bases de dados confiáveis e abrangentes, devido à complexidade para obtenção, custos e confidencialidade de informações. Tradicionalmente, a classificação dos regimes de padrões de escoamento é realizada por meio de análise visual manual, dependendo da experiência do operador ou de metodologias empíricas sujeitas a subjetividade e erros. Esse processo, além de demorado, é pouco escalável para as demandas da indústria petrolífera, que exige monitoramento contínuo e respostas rápidas para evitar perdas de produção e acidentes.

Diante desse cenário, o *Vertical Two-Phase Flow Regimes in an Annulus Image Dataset*, desenvolvido pela Texas A&M University, surge como um avanço crucial (MANIKONDA *et al.*, 2025). Trata-se de um repositório de imagens de alta fidelidade, obtidas em condições controladas e meticulosamente classificadas, servindo como base para o desenvolvimento de modelos de *machine learning* capazes de automatizar e aprimorar a identificação de padrões de escoamento.

Como ilustrado na Figura 1, o conjunto de dados engloba quatro padrões de escoamento canônicos: (a) Padrão borbulhante, que apresenta uma fase líquida contínua povoada por microbolhas de gás dispersas, (b) Padrão turbulento, manifestando interfaces de fase turbulentas e incoerentes, (c) Escoamento de slug, definido por bolsas periódicas de gás separadas por slugs de líquido, (d) Padrão de bolhas de Taylor, caracterizado por vazios de gás axialmente alongados que ocupam a secção transversal anular. A problemática central reside não apenas na complexidade física dos escoamentos, mas também na carência de dados sistematizados e na dependência de procedimentos manuais fatores que comprometem a eficiência e a segurança das operações petrolíferas.

Figura 1: Apresenta exemplos representativos dos quatro regimes de escoamento bifásico vertical.



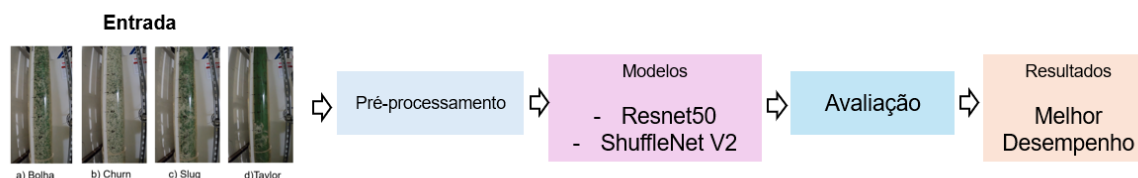
Fonte: Autoria própria. Adaptada de MANIKONDA et al. (2025).

Neste estudo, investigamos sistematicamente a utilização de técnicas de visão computacional o reconhecimento automático de regimes de escoamento. Duas arquiteturas de redes neurais convolucionais (CNN), a ResNet 50 e a ShuffleNet V2, são avaliadas e comparadas com métodos de aprendizagem automática baseados em texturas previamente testados, que empregam descritores de características artesanais. Este estudo procura não só melhorar o desempenho da classificação, mas também fornecer informações práticas para a concepção de soluções de monitorização eficientes e aplicáveis a sistemas de escoamento multifásico. Este trabalho centra-se na aplicação da visão computacional para classificar automaticamente estes padrões de escoamento.

## 2. METODOLOGIA

A Figura 2, representa a arquitetura utilizada no processo metodológico, onde dá-se início com o conjunto de imagens, em sequência aplicando-se o pré-processamento que consistiu no redimensionamento das imagens para uma resolução espacial fixa, padronizando as entradas para os modelos, e na normalização dos valores de pixel para o intervalo  $[0,1]$ , visando a estabilidade do treinamento (GOODFELLOW et al., 2016).

Figura 2: Arquitetura metodológica



Fonte: Autoria Própria

Duas abordagens de pré-processamento foram exploradas: (i) uso das imagens originais sem ajustes adicionais e (ii) aplicação de normalização do histograma para uniformizar brilho e contraste, minimizando variações de iluminação e ressaltando características morfológicas e texturais (SHORTEN; KHOSHGOFTAAR, 2019).

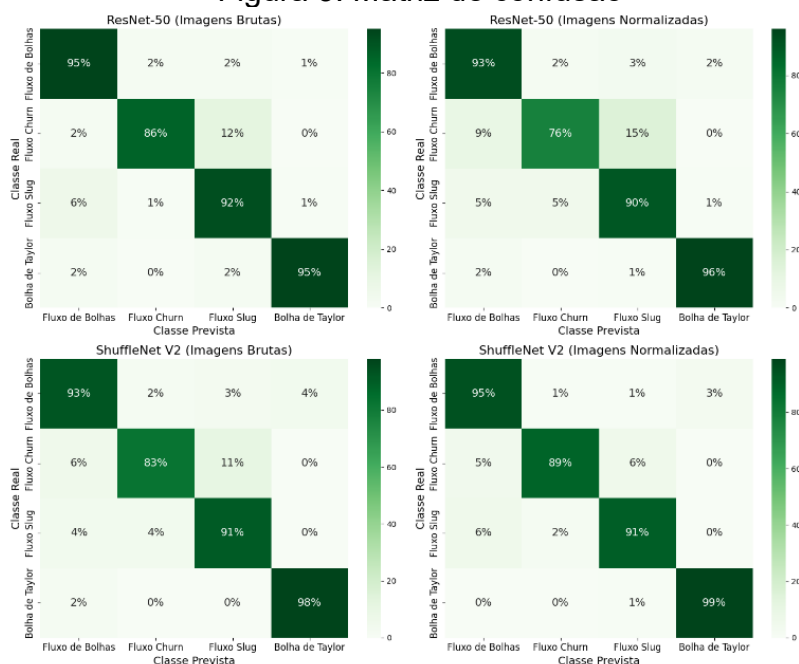
O conjunto de dados foi estratificado e dividido em treino (70%), validação (15%) e teste (15%), e a seleção do modelo empregou validação cruzada de 10 folds para garantir robustez dos resultados (KOHAVI, 1995). Foram avaliadas duas arquiteturas de redes neurais convolucionais: ResNet-50, que utiliza conexões residuais para facilitar o treinamento de redes profundas (HE et al., 2016; ZHANG et al., 2019), e ShuffleNet V2, uma arquitetura leve e eficiente que utiliza convoluções pontuais agrupadas e baralhamento de canais para manter precisão com menor custo computacional (Zhang et al., 2018). Ambos os modelos foram treinados para classificar quatro categorias, sob as duas configurações de pré-processamento. A avaliação do desempenho considerou métricas de acurácia global, precisão, recall e F1-score por classe, complementadas pela análise das matrizes de confusão para identificar padrões de erro, especialmente entre as classes padrões slug e churn (SOKOLOVA e LAPALME, 2009).

### 3. RESULTADOS E DISCUSSÃO

Conforme apresentado na Figura 3, estão as matrizes de confusão para cada modelo e configuração de pré-processamento. Cada linha corresponde à classe atual, enquanto as colunas indicam as classes previstas. As classes são ordenadas como: Padrão de escoamento de Bolhas, Padrão Slug, Padrão Churn, Bolha de Taylor.

A análise de desempenho, evidencia que o efeito da normalização varia entre modelos e classes. No padrão Slug, a ResNet-50 teve queda de 92% para 90%, enquanto a ShuffleNet V2 manteve desempenho em 91%. Nas Bolhas de Taylor, ambas ganharam desempenho, com os dois métodos, em especial a ShuffleNet V2 atingindo 99% com dados normalizados e reduzindo erros. No Padrão Churn, as precisões permaneceram acima de 76%, mas a ResNet-50 com dados normalizados apresentaram até 15% de confusão com o Padrão Slug, sugerindo que o classificador está confundindo os padrões por apresentarem características similares. Para Padrões de Bolhas, as taxas superaram 93% em todos os casos, com ganho marginal na ShuffleNet V2.

Figura 3: Matriz de confusão



Fonte: Autoria própria.

As matrizes de confusão revelam que os erros se concentram principalmente entre padrões Slug e Churn e, em menor grau, entre Padrão de Bolhas e Taylor, devido à semelhança morfológica das imagens. No geral, a normalização beneficiou mais a ShuffleNet V2, especialmente em classes minoritárias e complexas, enquanto a ResNet-50 apresentou maior estabilidade sem pré-processamento intensivo.

#### 4. CONCLUSÕES

Este estudo confirma que métodos de aprendizagem profunda são eficazes para classificar automaticamente padrões de escoamento gás-líquido a partir de imagens. O ResNet 50 alcançou maior precisão com desempenho superior a 95 % de acerto nas Bolhas de Taylor, especialmente com normalização do histograma, enquanto o ShuffleNet V2, com desempenho ligeiramente inferior, é mais eficiente computacionalmente, ideal para monitoramento em tempo real. A normalização do contraste melhora a identificação de classes minoritárias e casos visuais complexos. O trabalho ressalta a importância de equilibrar precisão e custo computacional na escolha do modelo e sugere ampliar o conjunto de dados com técnicas de aumento e filtragem para aprimorar a robustez da classificação.

#### 5. REFERÊNCIAS BIBLIOGRÁFICAS

- L. Zhang et al., Advances in Computational Regime Mapping for Gas–Liquid Systems: A Review, 2023.
- M. Tazikeh et al., Dynamic Characterization of Flow Regime Transitions in Vertical Pipelines, 2024.
- R. Chowdhury & A. F. Colombo, Applications of Topological Data Analysis in Multiphase Flow, 2024.
- Manikonda, K., Obi, C., Brahmane, A. A., Rahman, M. A., & Hasan, A. R. (2025). Vertical two-phase flow regimes in an annulus image dataset – Texas A&M University. Data in Brief, 58, 111245.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural features for image classification. IEEE Transactions on Systems, Man, and Cybernetics, SMC-3(6), 610–621.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 1–48.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI), 1137–1143.
- ZHANG, Jianpeng et al. Attention residual learning for skin lesion classification. IEEE transactions on medical imaging, v.38, n.9, p.2092-2103, 2019.
- ZHANG, Xiangyu et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2018. p.6848-6856.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. Information Processing & Management, 45(4), 427–437.