

ESTUDO EXPERIMENTAL DE MISTURAS MULTIFÁSICAS SUJEITAS A MOVIMENTO OSCILATÓRIO: VISUALIZAÇÃO COM CÂMERA DE ALTA VELOCIDADE E PROCESSAMENTO COM REDE NEURAL CONVOLUCIONAL

Palavras-Chave: INTELIGÊNCIA ARTIFICIAL, REDES NEURAIS, ESCOAMENTO DE PETRÓLEO

Autores(as): Thainá Nogueira de Oliveira Santos, FEQ/CEPETRO – UNICAMP
Dr. Rodolfo Marcilli Perissinotto, CEPETRO – UNICAMP
Dr. Natan Augusto Vieira Bulgarelli, CEPETRO – UNICAMP
Dr. William Monte Verde, CEPETRO – UNICAMP
Prof. Dr. Marcelo Souza de Castro, FEM/CEPETRO - UNICAMP

INTRODUÇÃO:

O transporte de petróleo em dutos envolve misturas de fases como água, óleo e gás. Essas misturas apresentam vários padrões de escoamento, impactando diretamente na eficiência e segurança da produção. Com o avanço da tecnologia aplicada às redes neurais de inteligência artificial, diferentes métodos têm sido desenvolvidos para otimização de processos. O presente estudo propõe o uso de redes neurais convolucionais [1, 2] para segmentar e estimar as frações volumétricas locais das fases em imagens de misturas capturadas por câmeras de alta velocidade em uma bancada oscilatória.

METODOLOGIA:

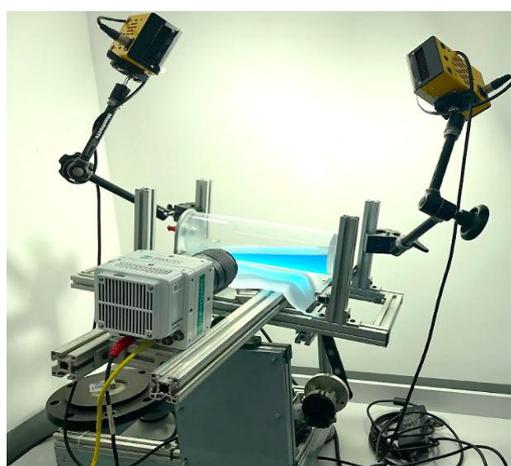


Figura 1 – Foto da bancada experimental.

A parte inicial do projeto foi dada pela construção da bancada experimental utilizada para reproduzir as diferentes condições de mistura. Para isso, a bancada foi construída com uma base retangular que sustenta um tubo transparente de 2,0 litros, acoplado a uma plataforma oscilatória movida por um motor elétrico, como ilustra a **Figura 1**. Um mecanismo do tipo biela-manivela promove o movimento de oscilação do tubo. À bancada, foi fixada uma câmera *Phantom* [3] de alta resolução, capaz de capturar 800 *frames* por segundo com 2500 x 1600 *pixels*. Os fluidos utilizados nos testes foram escolhidos com base em fases comuns da produção de petróleo: água, ar (parte leve gasosa), óleo mineral [4] (representando o petróleo em si).

Testes iniciais foram realizados a fim de determinar os limites de operação da bancada. Como a câmera faz a captura das imagens em escala de cinza, o contraste entre as fases foi manipulado para que houvesse maior distinção entre as mesmas. Portanto, a água foi pigmentada com azul de metileno na concentração de 0,01% m/m e o óleo corado com um corante amarelo usado para produção de velas. Por fim, os limites da frequência de oscilação do tubo foram estabelecidos entre 8 e 32 oscilações por minuto, a partir da avaliação da miscibilidade dos fluidos e formação de bolhas e gotas.

A **Tabela 1** contém a matriz de testes, com foco nas frações volumétricas escolhidas.

Tabela 1 – Fração volumétrica global de cada fase inserida no tubo transparente.

	Mistura bifásica ar-água			Mistura bifásica óleo-água			Mistura trifásica ar-óleo-água				
Fração de ar no tubo	75%	50%	25%	0%	0%	0%	50%	33%	10%	50%	10%
Fração de óleo no tubo	0%	0%	0%	75%	50%	25%	25%	33%	45%	40%	80%
Fração de água no tubo	25%	50%	75%	25%	50%	75%	25%	33%	45%	10%	10%

Processamento das imagens

Após a captura dos vídeos, as filmagens foram convertidas em aproximadamente 6 mil imagens por vídeo, das quais cerca de 20 imagens foram selecionadas para cada treinamento da rede neural, com padrão de qualidade suficiente (iluminação, contraste, nitidez). Após a seleção das imagens, foram feitas máscaras manuais de segmentação, a fim de correlacionar as fases da mistura ao tom de cinza correspondente. A **Figura 2** exemplifica uma imagem original e uma máscara, onde o tom branco foi selecionado para representar o ar, o cinza para o óleo mineral, e o preto para a água.

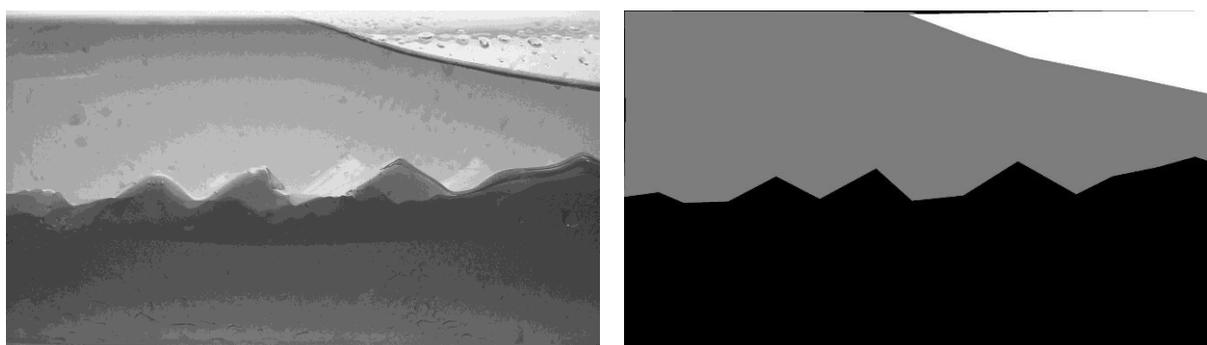


Figura 2 – Imagem real de mistura com 10% de ar, 45% de óleo, 45% de água (esq.) e segmentação manual (dir.).

O conjunto de imagens e máscaras foi então levado para a rede neural, que consiste em códigos próprios em linguagem *Python* [1, 2]. Um espaço de trabalho foi criado no *Anaconda Navigator* e utilizado em todo o processo. Nesse ambiente virtual, as principais bibliotecas empregadas foram *OS*, *NumPy*, *Keras*, *OpenCV* e *TensorFlow*. A etapa inicial do processamento envolveu o redimensionamento e a subdivisão das imagens e suas respectivas máscaras em pequenos quadrados de 64 x 64 *pixels*, com o objetivo de aumentar a quantidade de dados e também reduzir o custo computacional do treinamento.

Então, a etapa seguinte consistiu no treinamento da rede neural, ou seja, avaliação e ajuste de hiperparâmetros em 5 principais camadas: convolução, ativação, redução, conexão, saída [5]. A saída foram 10 modelos, em arquivos com extensão *h5*, gerados em cada treinamento. Esses modelos foram então aplicados às imagens originais da mistura para segmentar e identificar automaticamente as fases ar, óleo, água. A **Figura 3** contém um exemplo de imagem de mistura trifásica segmentada por um dos modelos gerados pela rede neural.

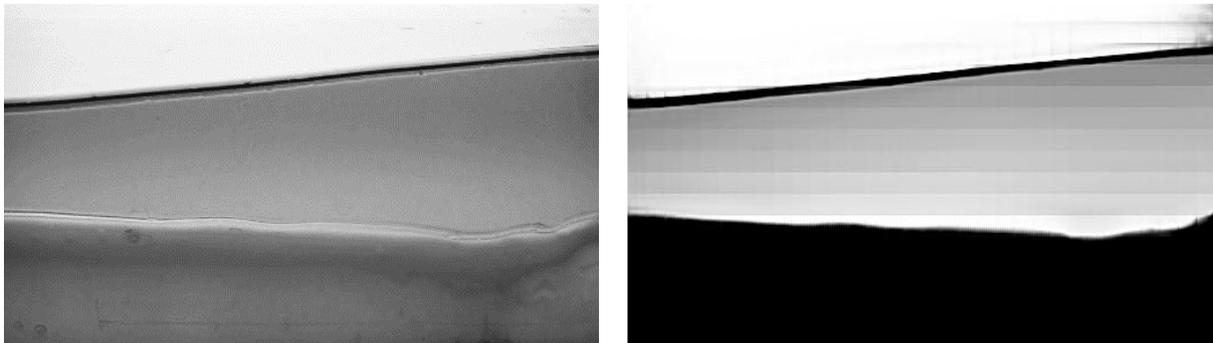


Figura 3 – Imagem real de mistura (esq.) e segmentação automática feita pela rede neural convolucional (dir.).

Por fim, as imagens segmentadas pelos modelos foram levadas a um último código para estimar as frações volumétricas locais das fases. O programa identifica os *pixels* em tons de cinza e classifica ar, óleo e água de acordo com uma escala na faixa de 0 (preto) a 255 (branco). A contabilização dos *pixels* que correspondem a cada fase é feita em posições definidas por *probes* virtuais, dispostas verticalmente e separadas na horizontal da imagem. O volume ocupado por cada *pixel* é finalmente calculado, a partir da atribuição de um “peso” em função da posição vertical do pixel. Esse peso busca transformar o dado de área da imagem (bidimensional) em um dado de volume (tridimensional).

RESULTADOS E DISCUSSÃO:

A **Figura 4** ilustra o resultado de uma segmentação seguida do cálculo das frações de volume ocupado por cada fase. À esquerda há uma imagem real, estática, com 50% de ar, 25% de óleo e 25% de água. À direita, a respectiva imagem segmentada pela rede neural e uma *probe* (linha vermelha) que mediu aproximadamente 50,6%, 24,3% e 25,1% de frações volumétricas. Na imagem estática, o valor das frações é conhecido e não muda em função da posição, assim é possível realizar uma comparação com os valores calculados na *probe*, para avaliação de desvios e incertezas dos modelos.

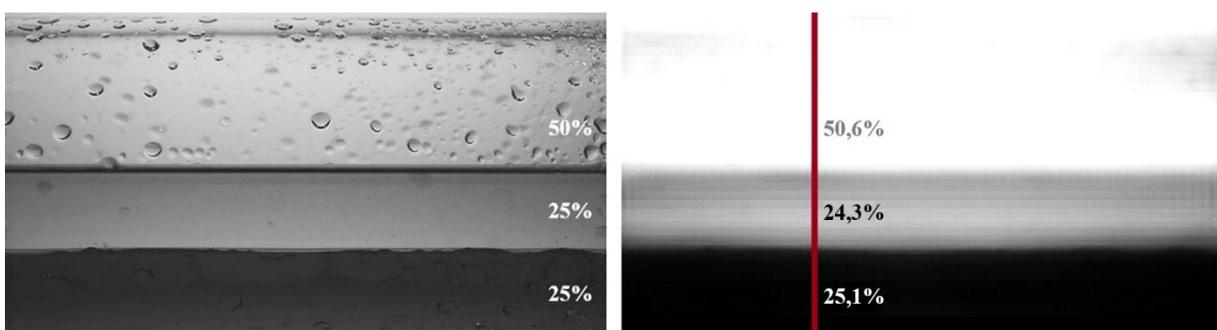


Figura 4 – Imagem real de mistura (esq.) e segmentação automática com medidas de fração volumétrica local (dir.).

No caso mostrado acima, o erro relativo da fração calculada em comparação com a fração real foi de 1,2% para o ar, 2,8% para o óleo e 0,4% para a água. No entanto, outros modelos apresentaram erros muito maiores, a depender da qualidade da imagem da mistura. Por funcionar em escala de cinza, a rede neural confunde as sombras, reflexões e mesmo as gotículas grudadas nas paredes do tubo com possíveis áreas de óleo e ar, o que pode dificultar a geração de modelos precisos. Quando se trata de áreas com muita mistura, óleo e água apresentam juntos um tom de cinza intermediário, o que também pode atrapalhar o nível de acerto da rede neural na segmentação das fases.

A **Figura 5** exibe um exemplo de imagem mais complexa, com presença de bolhas de ar e gotas de água entranhadas no óleo, e sua respectiva segmentação. A imagem real foi capturada em outra bancada experimental [2], com uma câmera capaz de obter imagens coloridas, e então foi processada pela rede neural descrita no atual estudo. A segmentação revela a dificuldade da rede neural identificar as bolhas e gotas. Em particular, as gotas de água entranhadas no óleo, que adquirem uma cor verde, acabam sendo classificadas como fase água, que é originalmente azul. Isso leva a uma superestimativa da fração de água e consequente subestimativa da fração de óleo.

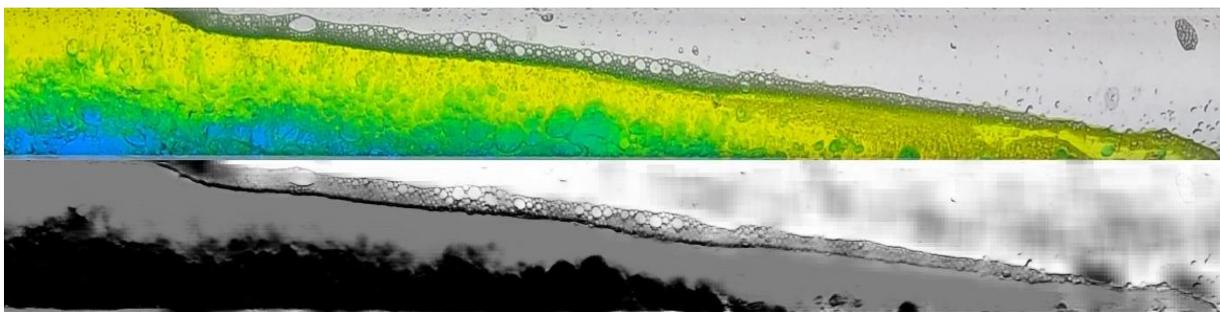


Figura 5 – Imagem colorida de mistura com bolhas e gotas dispersas (cima) e segmentação feita pela rede neural (baixo).

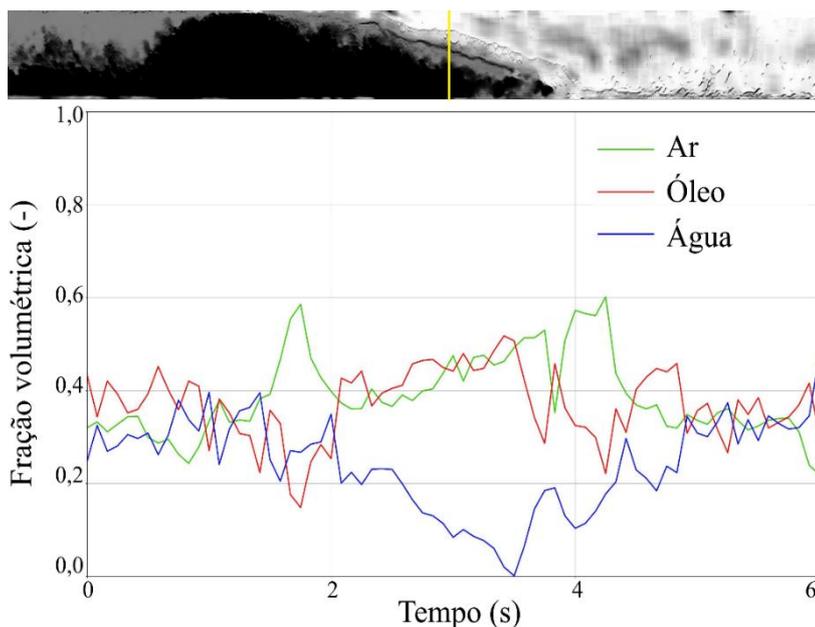


Figura 6 – Segmentação feita pela rede neural (cima) e gráfico da fração volumétrica no local da probe em função do tempo (baixo).

Apesar da necessidade de alguns ajustes, a rede neural conseguiu medir as frações locais com razoável exatidão e de forma instantânea, para todas as imagens que compõem cada vídeo. A **Figura 6** mostra um gráfico de frações por tempo, para um vídeo trifásico. Um instantâneo do vídeo é mostrado acima do gráfico. Esse *frame* corresponde ao tempo $t = 6$ segundos. Frações de ar, óleo e água são mostrados nas curvas verde, vermelha e azul, de acordo com estimativas feitas na posição da *probe* representada pela linha amarela.

CONCLUSÕES:

Para o treinamento e a aplicação da rede neural convolucional (CNN), o projeto de I.C. envolveu a aplicação de conceitos teóricos de programação e fotografia. A CNN desenvolvida e utilizada neste estudo mostrou-se uma ferramenta poderosa e promissora para o estudo de escoamentos na área de petróleo e energia. A automatização da análise de misturas multifásicas oferecida pela CNN tem como característica a substituição de trabalho repetitivo e demorado por validações mais rápidas e confiáveis.

Pequenos problemas na captura das imagens, como formação de sombras e manchas no tubo, influenciam na interpretação da rede neural. Embora a CNN tenha apresentado limitações em regiões das imagens com bolhas e gotas, os resultados obtidos em imagens de alta qualidade mostraram que a tecnologia de aprendizado de máquina tem muito potencial para ser aplicada em situações reais. O uso de ferramentas de inteligência artificial pode tornar análises complexas mais precisas e seguras.

BIBLIOGRAFIA

- [1] F. A. A. Mendes et al., “*Estimation of local volumetric phase fractions in transient multiphase flows: Assessment of an image processing tool based on machine learning and neural network*”, 12th North America Conference on Multiphase Production, Banff, Canadá, 2024.
- [2] J. D. Silva et al., “*Development of a deep learning based image processing technique for local phase fractions of multiphase transient flow*”, 20th Brazilian Congress of Thermal Sciences and Engineering, Foz do Iguaçu, Paraná, 2024.
- [3] Documentação técnica da câmera de alta velocidade modelo *Phantom VEO340*. Disponível em: <https://www.phantomhighspeed.com/products/cameras/veo/veoe340>. Acesso em: 30/06/2025.
- [4] FISPQ do óleo *Lucheti Luc LA 2225*. Disponível em: <https://lucheti.com.br>. Acesso em: 30/06/2025.
- [5] IBM. *Redes neurais convolucionais: uma abordagem de aprendizado profundo para análise de imagens*. Disponível em: <https://www.ibm.com/br-pt/think/topics/convolutional-neural-networks>. Acesso em: 30/06/2025.
- [6] Além da Superfície/IBP. *Setor de Petróleo e Gás Lidera PIB Industrial Brasileiro*. Disponível em: <https://www.alemadasuperficie.org/ibp/setor-de-petroleo-e-gas-lidera-pib-industrial-brasileiro> Acesso em: 30/06/2025.