DESENVOLVIMENTO DE MODELOS DE APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DE FRAÇÃO DE VAZIO EM ESCOAMENTO ÓLEO-AR VIA SINAIS DE ECO ULTRASSÔNICO

Palavras-Chave: ESCOAMENTO LÍQUIDO-GÁS, APRENDIZADO DE MÁQUINA, ULTRASSOM

Autores(as):

JÚLIA GOMES GONÇALVES DA CRUZ, FEQ – UNICAMP

Me. TIAGO FERREIRA SOUZA (coorientador), FEQ - UNICAMP

Prof. Dr. FLÁVIO VASCONCELOS DA SILVA (orientador), FEQ - UNICAMP

INTRODUÇÃO:

Escoamentos óleo-ar recebem a denominação de escoamentos bifásicos uma vez que o ocorre o transporte simultâneo de duas fases distintas. Esse tipo de escoamento é comum em diversos processos da indústria química, e seu monitoramento está relacionado com a otimização, segurança e aspectos econômicos do processo envolvido (Ren et al, 2021). Um dos desafios dessas indústrias é a necessidade de determinar a fração de gás livre no escoamento, denominada fração de vazio (Ren et al, 2021; Souza, 2021).

Técnicas baseadas em raios X, impedância elétrica e medidores ópticos estão entre as existentes para realizar a predição da fração de gás livre no escoamento (Figueiredo, 2016). Entretanto, problemas relacionados à segurança, alto custo, ou necessidade de tubulações transparentes dificultam suas aplicações. Uma alternativa a essas técnicas é a utilização de medidores ultrassônicos, pois apresentam baixo custo e fácil manuseio, além de poderem ser instalados de forma não intrusiva, ou seja, não obstruem o escoamento (Araújo, 2021; Figueiredo, 2016; Souza, 2021). Essa técnica consiste no uso de transdutores ultrassônicos que emitem ondas acústicas. Devido às características do escoamento, as ondas emitidas sofrem reflexões relativas à interface líquido-gás, resultando em alterações de parâmetros da onda acústica, como a amplitude. Assim, é possível extrair informações a partir de sua análise (Souza, 2021).

Os trabalhos de Figueiredo (2020) e Souza (2021) apresentam modelos empíricos para a predição de fração de vazio em escoamentos bifásicos utilizando sinais ultrassônicos obtidos por meio de medidas não intrusivas. No entanto, Figueiredo (2020) investigou apenas a faixa de 7,5 a 25% fração de vazio em escoamentos óleo-ar e obteve 18% de desvio em metade de seus resultados. Souza (2021), por sua vez, estimou essa variável fluidodinâmica de escoamentos bifásicos com desvios inferiores à 6%, mas se manteve em uma faixa mais restrita, de 1,5 a 13% de fração de vazio.

Diante do exposto, este trabalho teve por objetivo o desenvolvimento de diversos modelos de aprendizado de máquina (*machine learning*) para estimar a fração de vazio de escoamentos óleo-ar na faixa de valores de 8,0 a 70,0% a partir do processamento de sinais ultrassônicos. Os modelos de aprendizado de máquina desenvolvidos neste trabalho científico foram os seguintes: regressão linear/polinomial, árvore de decisão, floresta aleatória, máquinas de vetores de suporte e redes neurais artificiais.

METODOLOGIA:

O banco de dados utilizado engloba sinais de eco ultrassônico adquiridos experimentalmente de escoamentos óleo-ar na faixa de 8,0% a 70,0% de fração de vazio. Esses dados foram coletados no Laboratório de Controle e Automação de Processos (LCAP) localizado na Faculdade de Engenharia Química da Unicamp conforme o esquema mostrado na Figura 1. Para tanto, foi utilizado um transdutor de frequência central de 2,25 MHz durante 30 segundos. A frequência de repetição do pulso foi de 2000 Hz, de modo que o sinal ultrassônico contém 1100 pontos no total. Para cada amostra foram emitidos 32000 sinais de eco ultrassônico. Cada uma das amostras ultrassônicas presente no banco de dados foi proveniente de uma medição em diferentes condições de escoamento óleo-ar vertical e ascendente. Além disso, é importante notar que o banco de dados contém amostras referentes à três padrões distintos de escoamento: bolhas dispersas, pistonado e agitante, relacionados à diferentes distribuições das duas fases no escoamento. Um exemplo de sinal de eco ultrassônico é mostrado na Figura 2.

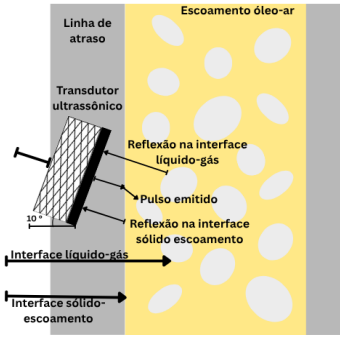

Figura 1 - Esquema da aquisição de sinais de eco ultrassônico. Adaptado de Souza (2021).

O processamento dos sinais de eco foi baseado na energia dos sinais de eco. A energia do sinal de eco é calculada pelo somatório das amplitudes, elevadas ao quadrado, do sinal de eco (Lathi, 2007). Essa variável é sensível à concentração e dispersão de bolhas no escoamento (Figueiredo, 2020; Souza, 2021) e, portanto, foi escolhida para o processamento. O cálculo da energia do sinal de eco foi aplicado para duas situações: ao sinal de eco completo, que engloba as reflexões relativas à interface líquido-gás do escoamento bifásico e a interface sólido-escoamento, e ao sinal de eco segmentado e relativo apenas às reflexões na interface líquido-gás. O resultado é um vetor denominado sinal de energia, ao qual foram aplicadas medidas estatísticas para serem usadas como variáveis de entrada dos modelos de aprendizado de máquina. As medidas estatísticas utilizadas foram a mediana, o coeficiente de variação (CV), a entropia de Shannon e a média do sinal de energia (Smith, 2003).

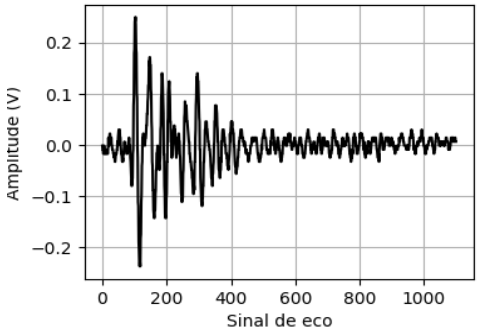

Figura 2 - Exemplo de sinal coletado. Autor, 2025.

Os modelos de aprendizado de máquina avaliados foram dos tipos regressão linear/polinomial (*linear/polynomial regression* - L/PR), árvore de decisão (*decision tree* - DT), floresta aleatória (*random forest* - RF), máquinas de vetores de suporte (*support vector machines* - SVR) e redes neurais (*artificial neural network* - ANN). O modelo de regressão linear foi escolhido pela sua simplicidade e interpretabilidade. Além disso, o modelo de regressão polinomial também foi estudado, em que o grau do polinômio é escolhido como hiperparâmetro (Kuhn e Johnson, 2013). Também, avaliou-se os modelos baseados em árvores: a árvore de decisão e a floresta aleatória. A árvore de decisão funciona a partir da divisão dos dados em subconjuntos menores utilizando regras do tipo se-então (*if-then*), encontrando a divisão cujo erro na predição da variável de saída é menor. O processo se repete, dando origem aos chamados nós e folhas, o que faz com que o valor de cada folha seja atribuído pela média dos dados de testes daquela região (Kuhn e Johnson, 2013; Müller e Guido, 2007). A floresta aleatória, por sua vez, trata-se de um conjunto de árvores de decisão treinadas com diferentes partições do banco de dados. A resposta final é dada considerando a média de cada árvore de decisão. Esse algoritmo de aprendizado de máquina é um dos mais robustos disponíveis e destaca-se por introduzir elementos de aleatoriedade ao processo de treinamento, contribuindo para sua capacidade de generalização (Géron, 2017). As máquinas de vetores de suporte foram outro tipo de algoritmo estudado. O objetivo desse algoritmo é encontrar uma função que se adeque aos dados, definindo uma margem de erro ao seu redor. Os pontos localizados fora desse limiar são chamados de vetores de suporte e sua penalização é responsável por influenciar o modelo (Kuhn e Johnson, 2013). O modelo apresenta bom comportamento com dados não lineares pois pode utilizar funções em espaços multidimensionais (Awad e Khanna, 2015; Kuhn e Johnson, 2013). Por fim, foi também avaliado o modelo de rede neural artificial. As redes neurais baseiam-

se no funcionamento do cérebro humano. A forma de uma rede neural engloba uma camada de entrada, pelo menos uma camada oculta e uma camada de saída. Em cada camada estão presentes os neurônios, os quais são combinações lineares das variáveis de entrada ou de neurônios da camada anterior, normalmente transformados pela aplicação de uma função de ativação (Kuhn e Johnson, 2013).

Para o desenvolvimento dos modelos foi utilizada a linguagem de programação *Python*, com a biblioteca *SciKit-Learn* (Pedregosa, 2011). Após a seleção das variáveis de entrada, separou-se o banco de dados em dois conjuntos: 80% dos dados foram utilizados para o treinamento dos modelos e 20% foram separados para teste. É importante ressaltar que o mesmo estado aleatório foi utilizado para o treinamento dos diferentes modelos, de modo que todos eles foram treinados no mesmo conjunto de dados. Além da divisão do banco de dados, foi feita a normalização dos dados entre -1 e 1. Para cada um dos modelos estudados é necessário realizar a sintonia de hiperparâmetros. Essa etapa é importante pois permite a seleção do modelo com melhor performance de determinado algoritmo (Kuhn e Johnson, 2013). A faixa de hiperparâmetros avaliados é mostrada na Tabela 1.

Modelo	Hiperparâmetro	Faixa
L/PR	Grau do polinômio (*degree* – D)	D: [1; 2; 3; 4; 5; 6; 7; 8; 9]
DT	Profundidade máxima (PM), mínimo de amostras para dividir um nó (MN), mínimo de amostras por folha (MF)	PM: [1; 5; 10; 100], MN: [2; 5; 10; 50; 100], MF: [2; 5; 10; 100; 1000]
RF	Número de árvores (A), profundidade máxima (PM), mínimo de amostras para dividisão (MN), mínimo de amostras por folha (MF), máximo de características (MC)	A: [50; 100; 200], PM: [None; 5; 10], MN: [2; 5; 10], MF: [1; 2; 4], MC: [1; 2; 3; 4]
SVR	Kernel (K), regularização (C), gamma (G), Tolerância (ε)	K: ['rbf'; 'linear'; 'poly' (D: 3; 4; 5)], C: [0,01; 0,1; 1; 10; 100], G: [0,01; 0,1; 1; 10; 100], ε: [0,01; 0,1; 1; 10; 100]
ANN	Número de neurônios (N), função de ativação (FA), alpha (A), taxa de aprendizado (TA), parada antecipada (PA)	N: , FA: ['relu'; 'tanh'; 'identity'; 'logistic'], A: [0,001; 0,01; 0,1], TA: [0,0001; 0,001; 0,01], PA: [False, True]

Tabela 1 - Faixa de hiperparâmetros avaliados

O procedimento de sintonia de hiperparâmetros foi realizado utilizando a técnica de busca em grade (*grid search*) com validação cruzada (*cross validation*). A busca em grade consiste no treinamento e validação do modelo para um dos conjuntos possíveis de hiperparâmetros. A validação do modelo pelo método de validação cruzada foi feita dividindo o banco de dados em cinco subconjuntos mutuamente excludentes. O treinamento é feito com quatro dessas partições, de modo que a avaliação do modelo é feita com o subconjunto restante. Esse procedimento é realizado cinco vezes e a média das métricas de desempenho é calculada, permitindo a seleção do modelo com melhor métrica de desempenho (Kuhn e Johnson, 2013).

Após a determinação do melhor conjunto de hiperparâmetros de cada modelo, realizou-se o teste de cada um deles usando os 20% do banco de dados reservados para essa finalidade. Desse modo, foi possível identificar os modelos de aprendizado de máquina plausíveis para a tarefa de predição de fração de vazio.

RESULTADOS E DISCUSSÃO:

O processamento dos sinais de eco ultrassônico, com a aplicação das medidas estatísticas ao sinal de energia, resultou nas variáveis mais correlacionadas com a fração de vazio. A relação entre essas variáveis e a fração de vazio é mostrada na Figura 3.

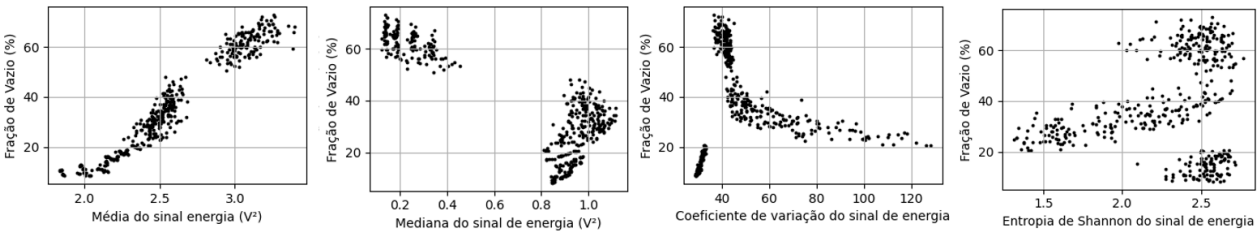

Figura 3 - Relação entre fração de vazio e medidas estatísticas aplicadas ao sinal de energia

Essas variáveis foram a média do sinal de energia considerando o sinal completo, a mediana, o coeficiente de variação e a entropia de Shannon considerando o sinal de energia relativo ao escoamento no interior da tubulação. Desse modo, essas variáveis foram escolhidas como entrada dos modelos de aprendizado de máquina.

Observa-se que em nenhum dos casos as variáveis analisadas em relação à fração de vazio apresentam comportamento linear, com exceção da média do sinal de energia que apresenta comportamento próximo da linearidade. Além disso, nota-se a presença dos três grupos distintos de escoamento para a mediana e a entropia de Shannon do sinal de energia, relacionados com os três padrões de escoamento presentes no banco de dados. O coeficiente de variação, por sua vez, apresenta uma tendência inicialmente crescente na primeira região do gráfico e decrescente a partir de CV igual a 40. Desse modo, a média do sinal de energia, calculada a partir do sinal completo, e a mediana, o coeficiente de variação e a entropia de Shannon, calculadas a partir do sinal referente ao escoamento no interior da tubulação, foram utilizadas como variáveis de entrada dos modelos de aprendizado de máquina.

A etapa de treinamento e seleção de hiperparâmetros indicou o melhor conjunto de hiperparâmetros para cada algoritmo, mostrados na Tabela 2, juntamente com os valores de erro médio quadrático (MSE) da validação cruzada.

Modelo	Hiperparâmetro	MSE da validação cruzada
L/PR	D: 1	0,0441
DT	PM: 5; MN: 5; MF: 100;	0,0148
RF	A: 200; PM: 10; MN: 10; MF: 4; MC: 2	0,0101
SVR	K: 'rbf'; C: 1; G: 1; ε: 0,01	0,0101
ANN	N: 14; FA: 'relu'; A: 0,1; TA: 0,01; PA: False	0,0167

Tabela 2 – Resultados dos conjuntos com melhores hiperparâmetros de cada algoritmo

O teste dos modelos foi realizado com o conjunto de hiperparâmetros da Tabela 2, usando os 20% de dados presentes no banco de teste. Os resultados de valores reais em função dos preditos de fração de vazio estão apresentados nas Figura 4, 5, 6, 7 e 8 em conjunto com as métricas de desempenho de cada teste.

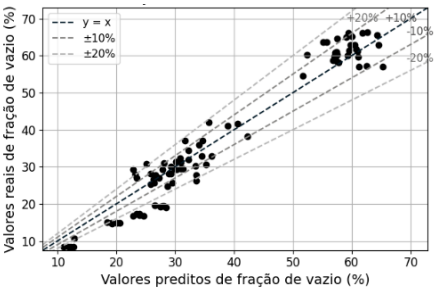

RMSE	4,39%
MAPE	14,04%
R^2	0,943

Figura 4 – Resultados do teste do modelo L/PR

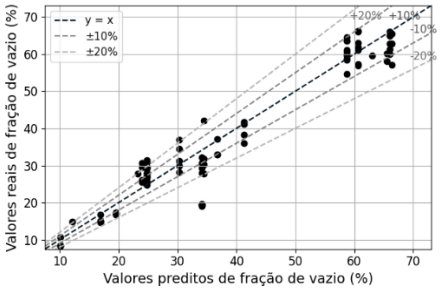

RMSE	5,00%
MAPE	13,26%
R^2	0,926

Figura 5 – Resultados do teste do modelo DT

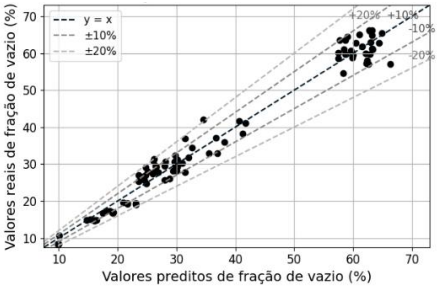

RMSE	2,89%
MAPE	7,21%
R^2	0,975

Figura 6 – Resultados do teste do modelo RF

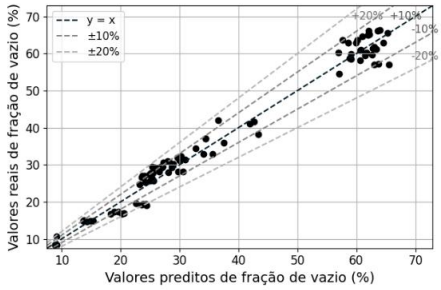

RMSE	2,82%
MAPE	7,35%
R^2	0,976

Figura 7 – Resultados do teste do modelo SVR

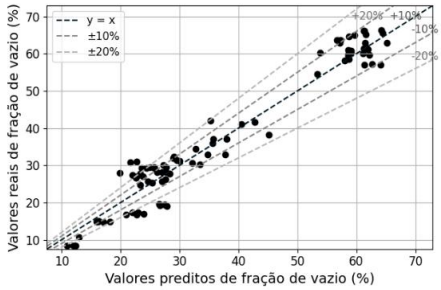

RMSE	4,15%
MAPE	12,86%
R^2	0,949

Figura 8 – Resultados do teste do modelo ANN

A partir da análise dessas figuras, é possível perceber que os modelos de floresta aleatória (RF) e máquinas de vetores de suporte (SVR) apresentaram melhores desempenhos em relação aos outros modelos, justificado pelos valores inferiores de raiz do erro médio quadrático (RMSE) e

erro médio percentual absoluto (MAPE). O restante dos modelos apresentou desempenho similar entre eles, no entanto, com maiores valores de métricas de erro.

Os resultados para os modelos de melhor performance mostraram-se superiores aos obtidos por Figueiredo (2020) e Souza (2021), uma vez que os desvios relativos foram menores e a faixa de fração de vazio estudada foi maior, respectivamente. Além disso, também pode-se comparar os resultados deste trabalho aos resultados obtidos por Ren et al (2021). Ren et al (2021) desenvolveram um sistema de coleta de dados ultrassônicos utilizando um transmissor e um receptor de pulsos acústicos. Em seguida, aplicaram algoritmos de aprendizado profundo, combinando uma rede neural convolucional com memória de longo e curto prazo (*long short-term memory* – LSTM), a fim de predizer a fração de vazio, obtendo um MAPE de 4,25% e um R^2 de 0,990. Nota-se que os modelos de aprendizado de máquina mais simples apresentaram resultados inferiores neste trabalho. No entanto, é importante considerar que o custo computacional para o aprendizado profundo é maior em comparação aos modelos desenvolvidos neste trabalho (Goodfellow et al, 2016).

CONCLUSÕES:

Portanto, é possível concluir que o processamento de sinais de eco ultrassônicos provenientes de medidas não intrusivas apresenta-se como uma alternativa para a predição da variável fluidodinâmica fração de vazio. A aplicação de medidas estatísticas ao sinal de energia indicou a existência de correlação com a fração de vazio. Além disso, entre os modelos de aprendizado de máquina em que essas variáveis foram aplicadas como entrada, a floresta aleatória e as máquinas de vetores de suporte, mostraram-se como modelos adequados para a realizar a tarefa de predição de fração de vazio em escoamentos líquido-gás.

BIBLIOGRAFIA

ARAÚJO, Caio César Silva. **Sistema ultrassônico para determinação do perfil de velocidade, da fração de vazio e da vazão da fase dispersa em coluna de bolhas.** 2021. 72 f. Dissertação (Mestrado) - Engenharia Química, Universidade Estadual de Campinas, Campinas, 2021.

FIGUEIREDO, Maurício de Melo Freire. **Caracterização de escoamentos verticais bifásicos utilizando ultrassom.** 2020. Tese (Doutorado em Engenharia Mecânica) — Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2020.

FIGUEIREDO MMF, GONCALVES JL, NAKASHIMA AMV, FILETI AMF, CARVALHO RDM, The use of an ultrasonic technique and neural networks for identification of the flow pattern and measurement of the gas volume fraction in multiphase flows. **Exp. Therm. Fluid Sci**., v. 70, p. 29-50, jan. 2016. Elsevier BV. http://dx.doi.org/10.1016/j.expthermflusci.2015.08.010.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems.** 1. ed. Sebastopol: O'Reilly Media, 2017.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning.** Cambridge: MIT Press, 2016.

GZAR, Dunia Abas; MAHMOOD, Ali Majeed; ABBAS, Maythem K. A Comparative Study of Regression Machine Learning Algorithms: Tradeoff Between Accuracy and Computational Complexity. **Mathematical Modelling and Engineering Problems**, v. 9, n. 5, p. 1217–1224, dez. 2022. Disponível em: DOI: 10.18280/mmep.090508.

LATHI, Bhagwandas Pannalal. **Sinais e Sistemas Lineares**. 2. ed. Porto Alegre: Bookman, 2007.

KUHN, Max. e JOHNSON, Kjell. **Applied Predictive Modeling.** 1. ed. Nova York: Springer, 2013.

MÜLLER AC, GUIDO S, **Introduction to Machine Learning with Python: a guide for data scientists.** Sebastopol: O'reilly Media, Inc., 2016.

PEDREGOSA, Fabian et al. *Scikit-learn: Machine learning in Python*. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. 12(85):2825−2830

REN, Weikai; JIN, Ningde; OUYANG, Lei; ZHAI, Lusheng; REN, Yingyu. Gas Volume Fraction Measurement of Oil–Gas–Water Three-Phase Flows in Vertical Pipe by Combining Ultrasonic Sensor and Deep Attention Network. **Ieee Transactions on Instrumentation and Measurement**, v. 70, p. 1-9, 2021. Institute of Electrical and Electronics Engineers (IEEE). http://dx.doi.org/10.1109/tim.2020.3031186.

SOUZA, Tiago Ferreira. **Desenvolvimento de uma técnica ultrassônica para a estimativa da fração de vazio e vazão da fase dispersa de escoamentos água-ar.** 2021. 100 f. Dissertação (Mestrado) - Curso de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2021.