Encontro Nacional do Programa de Formação de Recursos Humanos da ANP - 2026

Análise de Padrões de Escoamento Multifásicos em sistemas *Core-annular Flow* usando Fluidodinâmica Computacional

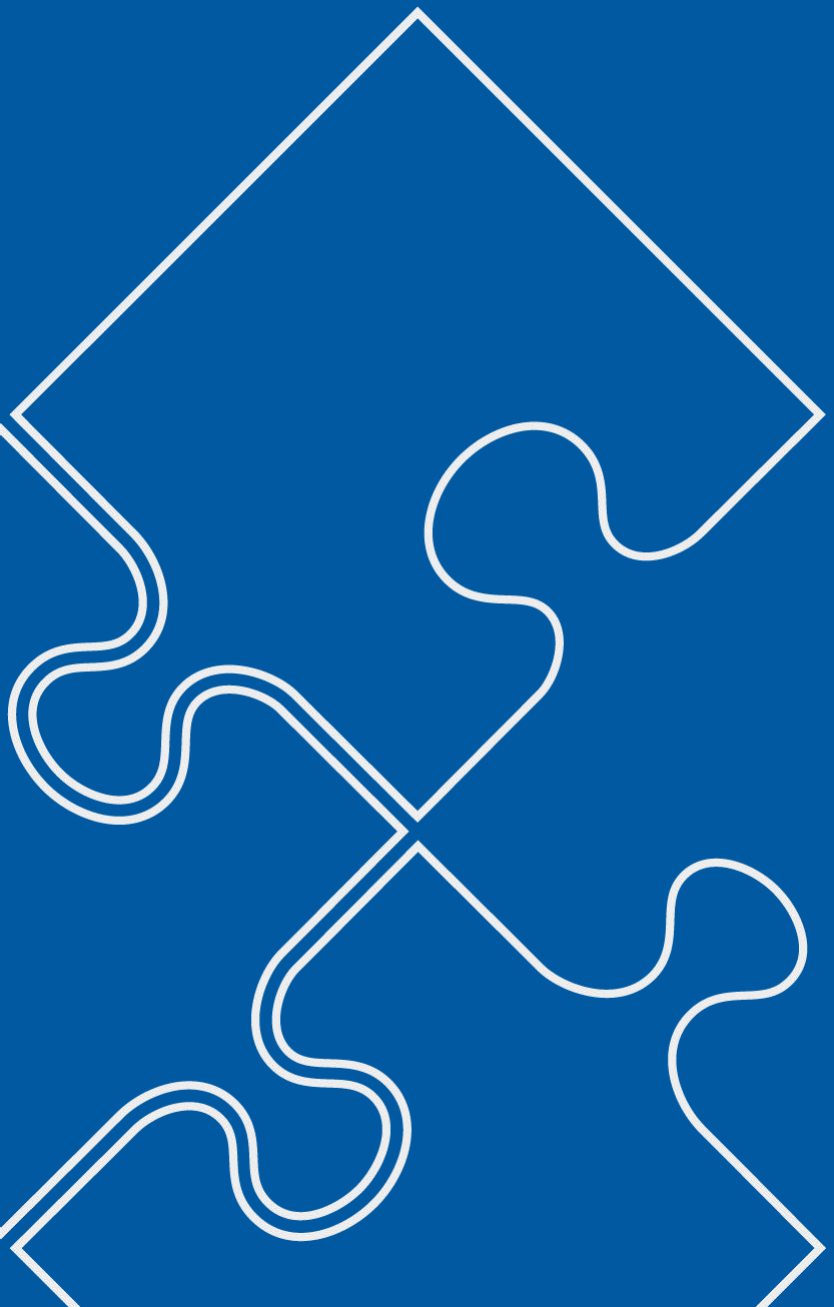
Camila Oliveira dos Santos Borges; Márcio Andre Fernandes Martins; Leonardo Silva de Sousa; Nuccia Carla Arruda de Souza

PRH 41/UFBA

Tipo de bolsa: Mestrado

Universidade Federal da Bahia (UFBA)

Gestão:



1

Motivação

Aproveitamento de Ativos

- Os óleos pesados e extrapesados totalizam cerca de 40% das reservas mundiais de petróleo;
- Cenáro nacional: A maioria dos campos de óleo pesado e ultraviscoso no Brasil são Campos Maduros;
- Maximização do aproveitamento de ativos existentes.

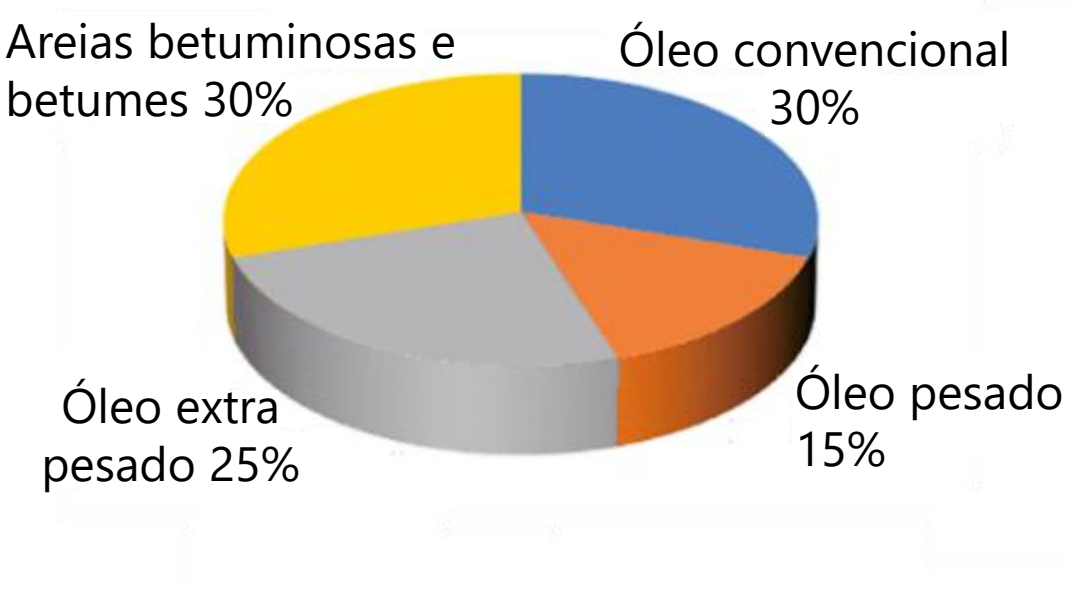


Figura 1: Total de reservas de óleo pesado.
Fonte: Gomaa, Sayed, Khalaf G. Salem e AN El-hoshoudy. (2016).

Desafios no Transporte de Óleos Pesados

- Efeitos de atrito friccional;
- Perda de carga elevada;
- Alta demanda do sistema de propulsão;
- Alto custo de bombeamento na extração;
- Técnica core-annular flow.

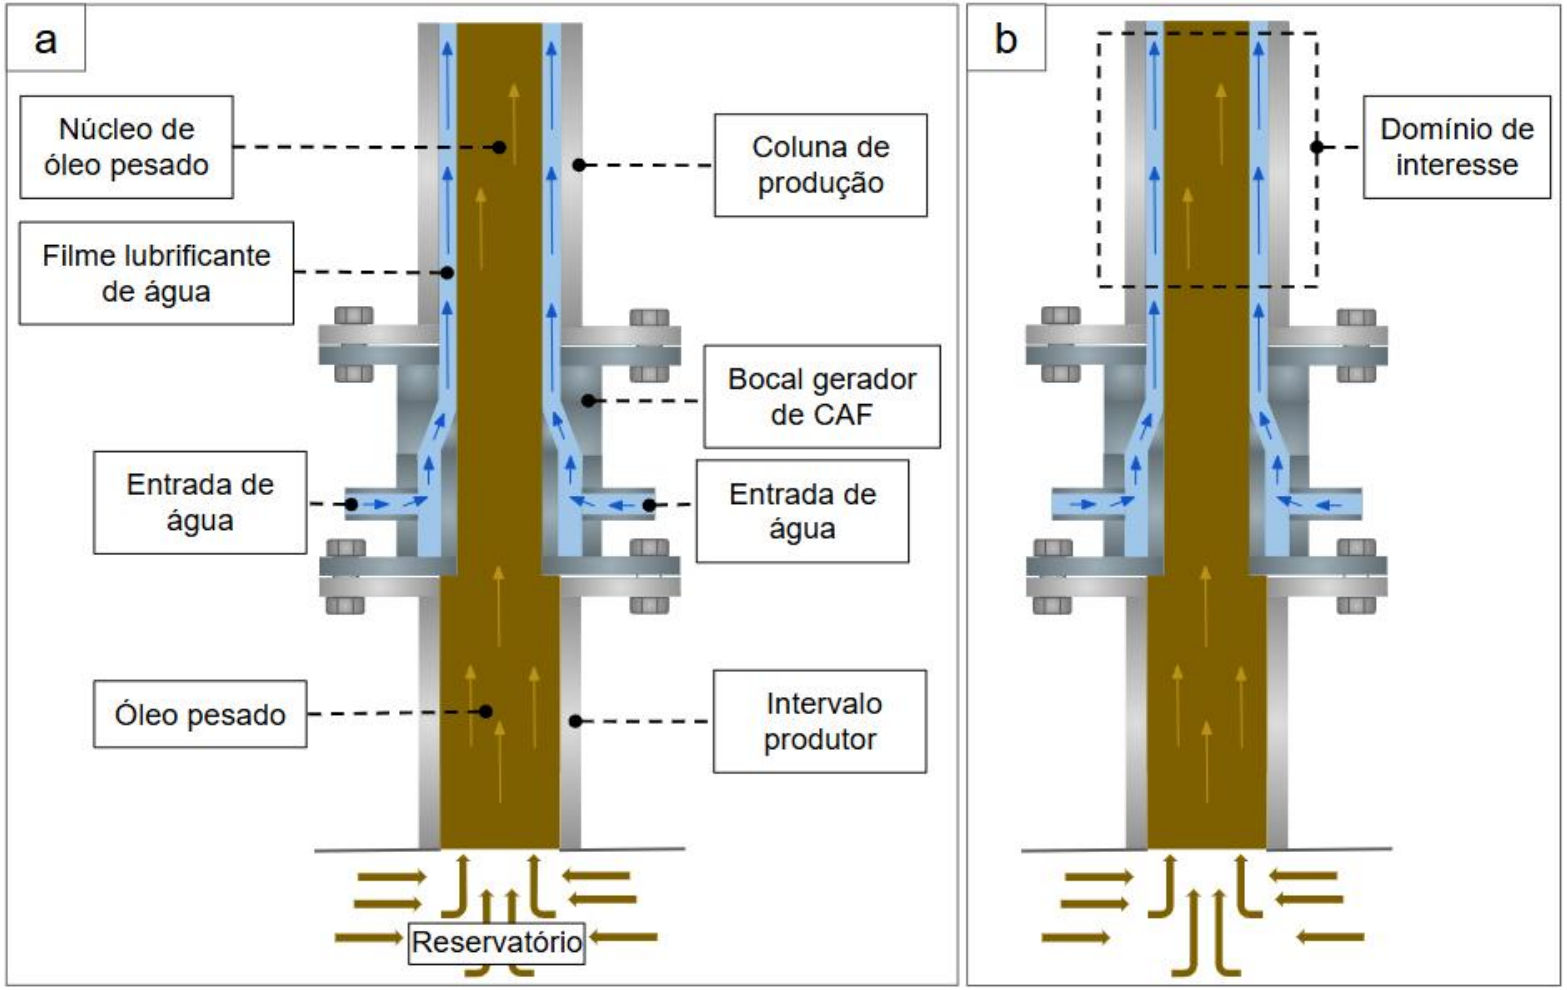


Figure 2: Funcionamento da técnica core annular flow.
Fonte: Autoria própria (2026).

Diversidade de padrões de escoamento

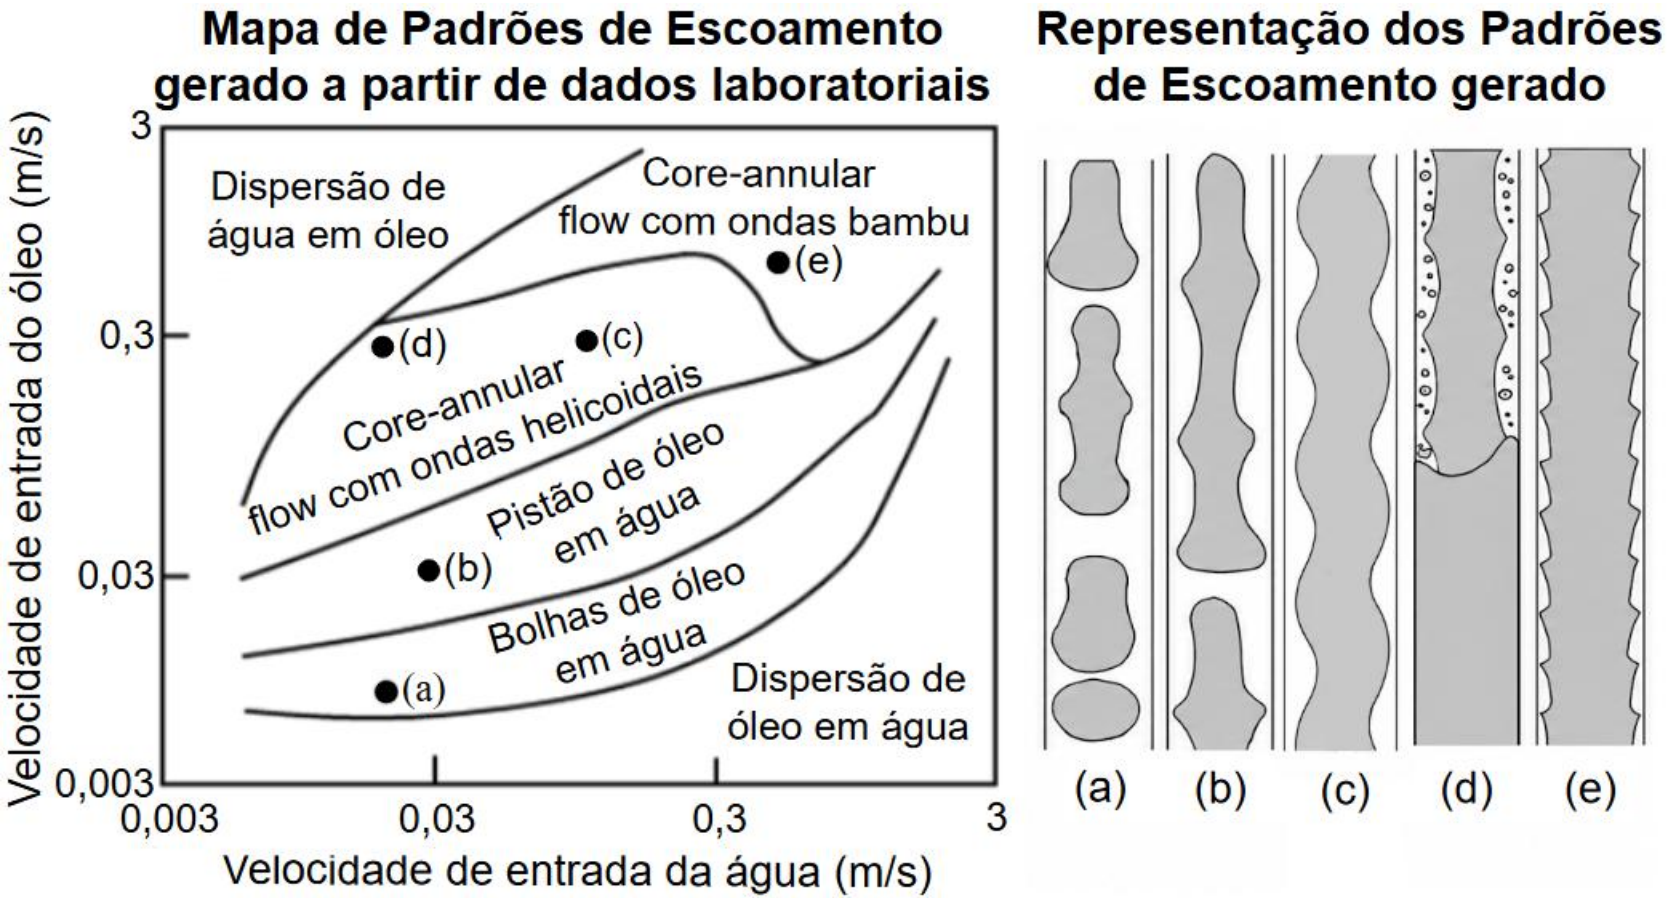
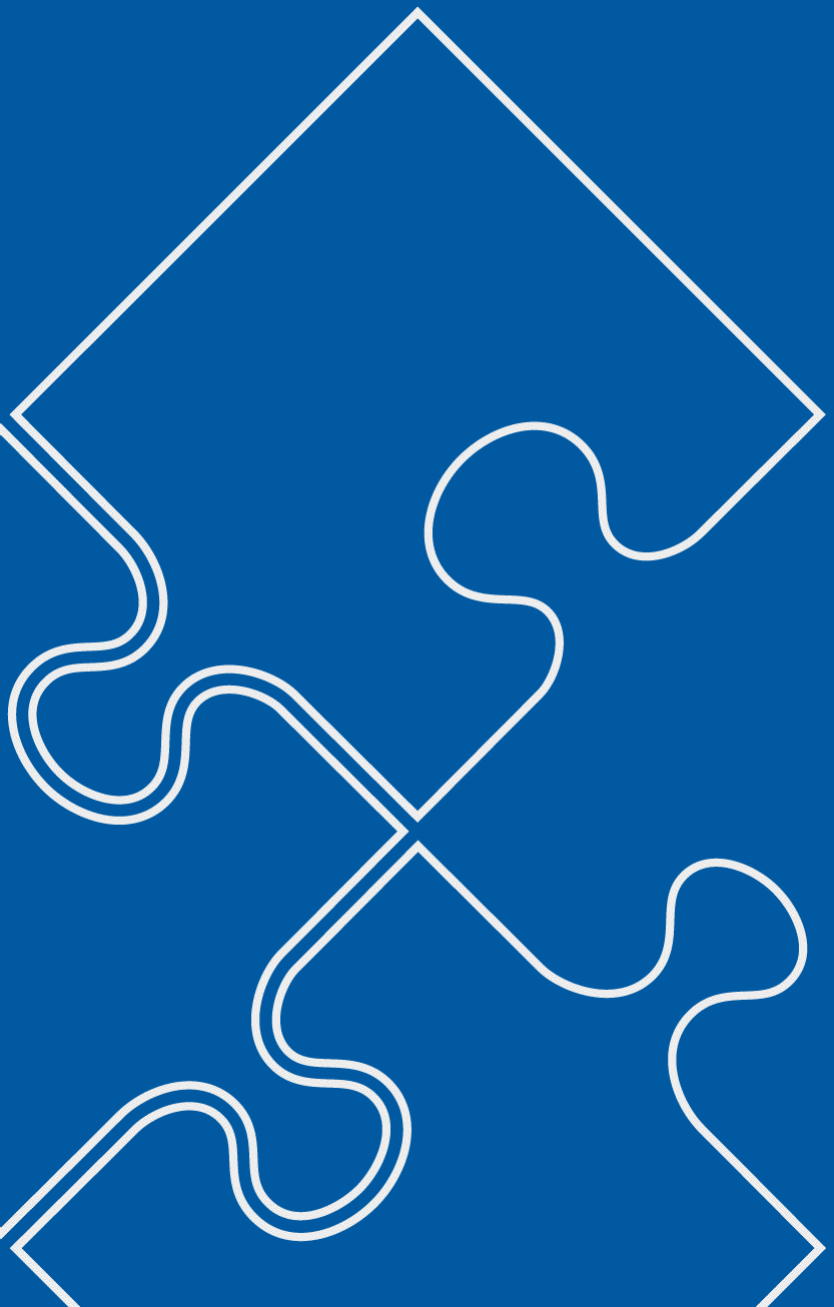


Figura 3 - Padrões de escoamento.
Fonte: Joseph, Renardy e Renardy (1984).

Objetivo

- Desenvolver um classificador de padrões de escoamento água-óleo ascendente na técnica de core-annular flow, a partir da integração entre simulações de Fluidodinâmica Computacional e modelos de aprendizado de máquina, de modo a estabelecer uma base para aplicações futuras em monitoramento e controle inteligente na indústria de óleo e gás.



2

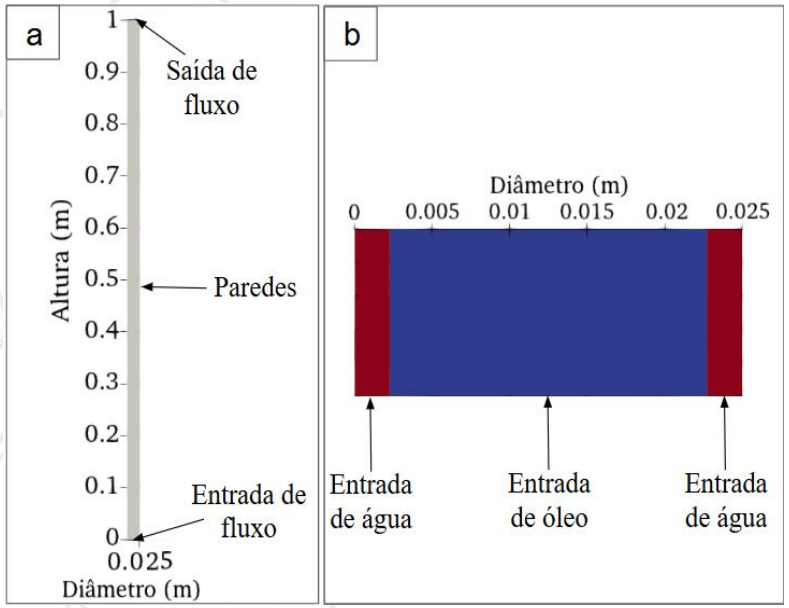
Método: Fluidodinâmica Computacional

Fluidodinâmica Computacional

- A Fluidodinâmica Computacional é a área do conhecimento que estuda sistemas envolvendo escoamento de fluidos, por meio de simulações numéricas.

Modelo Computacional

Pré-processamento



Processamento

Equação de balanço de massa

$$\frac{\partial \alpha}{\partial t} + \nabla \cdot (\alpha \mathbf{U}) + \nabla \cdot [\alpha(1-\alpha)\mathbf{U}_r] = 0$$

Equação de balanço da quantidade de movimento

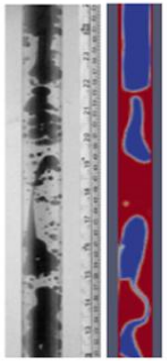
$$\frac{\partial(\rho \mathbf{U})}{\partial t} + \nabla \cdot (\rho \mathbf{U} \otimes \mathbf{U}) = -\nabla p + \nabla \cdot \left[\mu \left(\nabla \mathbf{U} + \nabla \mathbf{U}^{\mathrm{T}}\right)\right] + \rho \mathbf{g} + \mathbf{F}_{\sigma}$$

Modelo de turbulência de transporte de tensão cisalhante (SST)

$$\frac{\partial(\rho k)}{\partial t} + \frac{\partial(\rho u_j k)}{\partial x_j} = P_k - \beta^* \rho k \omega + \frac{\partial}{\partial x_j}\left[(\mu + \sigma_k \mu_t)\frac{\partial k}{\partial x_j}\right]$$

$$\frac{\partial(\rho \omega)}{\partial t} + \frac{\partial(\rho u_j \omega)}{\partial x_j} = \alpha \frac{\omega}{k} P_k - \beta \rho \omega^2 + \frac{\partial}{\partial x_j}\left[(\mu + \sigma_\omega \mu_t)\frac{\partial \omega}{\partial x_j}\right] + 2(1-F_1)\rho \sigma_{\omega 2}\frac{1}{\omega}\frac{\partial k}{\partial x_j}\frac{\partial \omega}{\partial x_j}$$

Pós-processamento

Bolhas de óleo em água
Velocidade da água: 0,15 m/s Velocidade do óleo: 0,07 m/s


Validação qualitativa

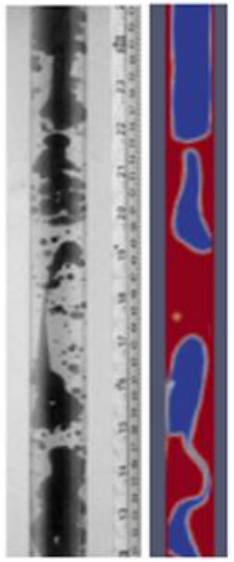
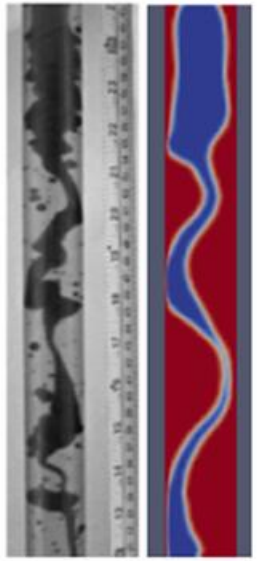
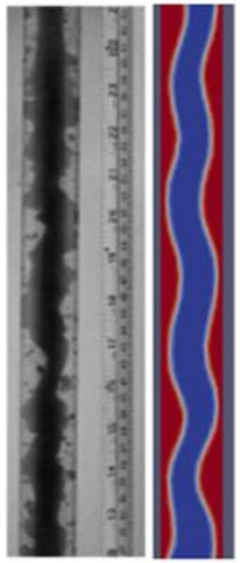
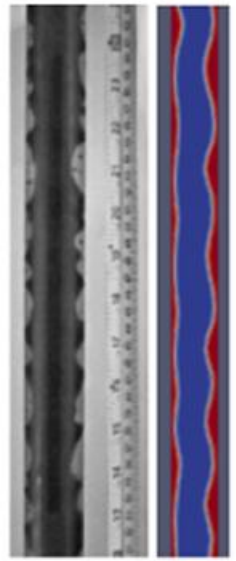
Bolhas de óleo em água	Pistão de óleo em água	Core-annular com ondas helicoidais	Core-annular com ondas de bambu
Velocidade da água: 0,15 m/s Velocidade do óleo: 0,07 m/s	Velocidade da água: 0,21 m/s Velocidade do óleo: 0,07 m/s	Velocidade da água: 0,46 m/s Velocidade do óleo: 0,26 m/s	Velocidade da água: 0,21 m/s Velocidade do óleo: 0,33 m/s
			

Figura 4 - Análise comparativa entre os modelos computacionais e experimentais.
Fonte: Autoria própria com base em Coelho et al. 2020.

Coleta de dados

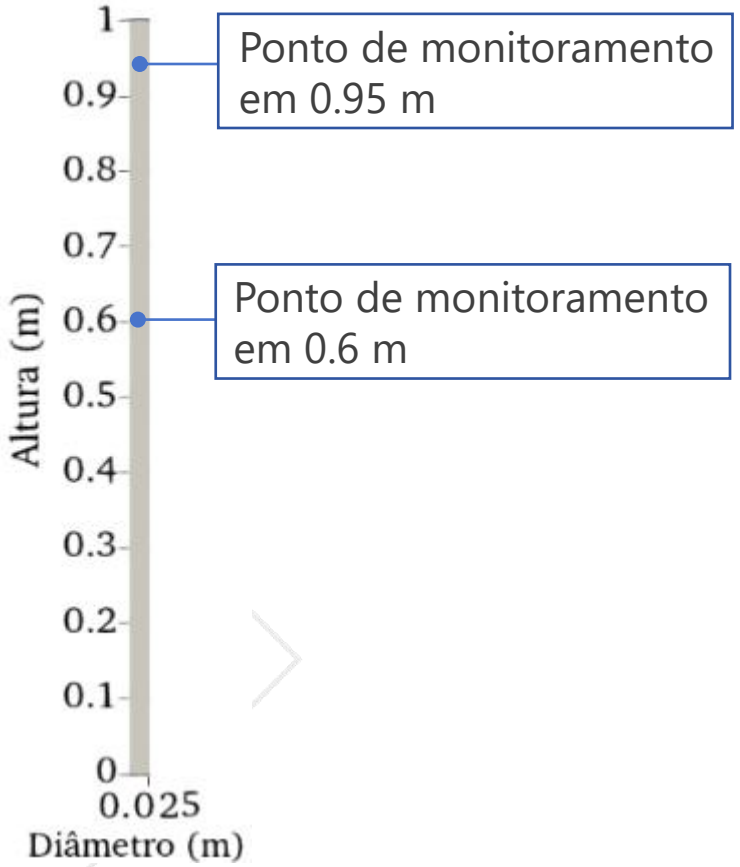


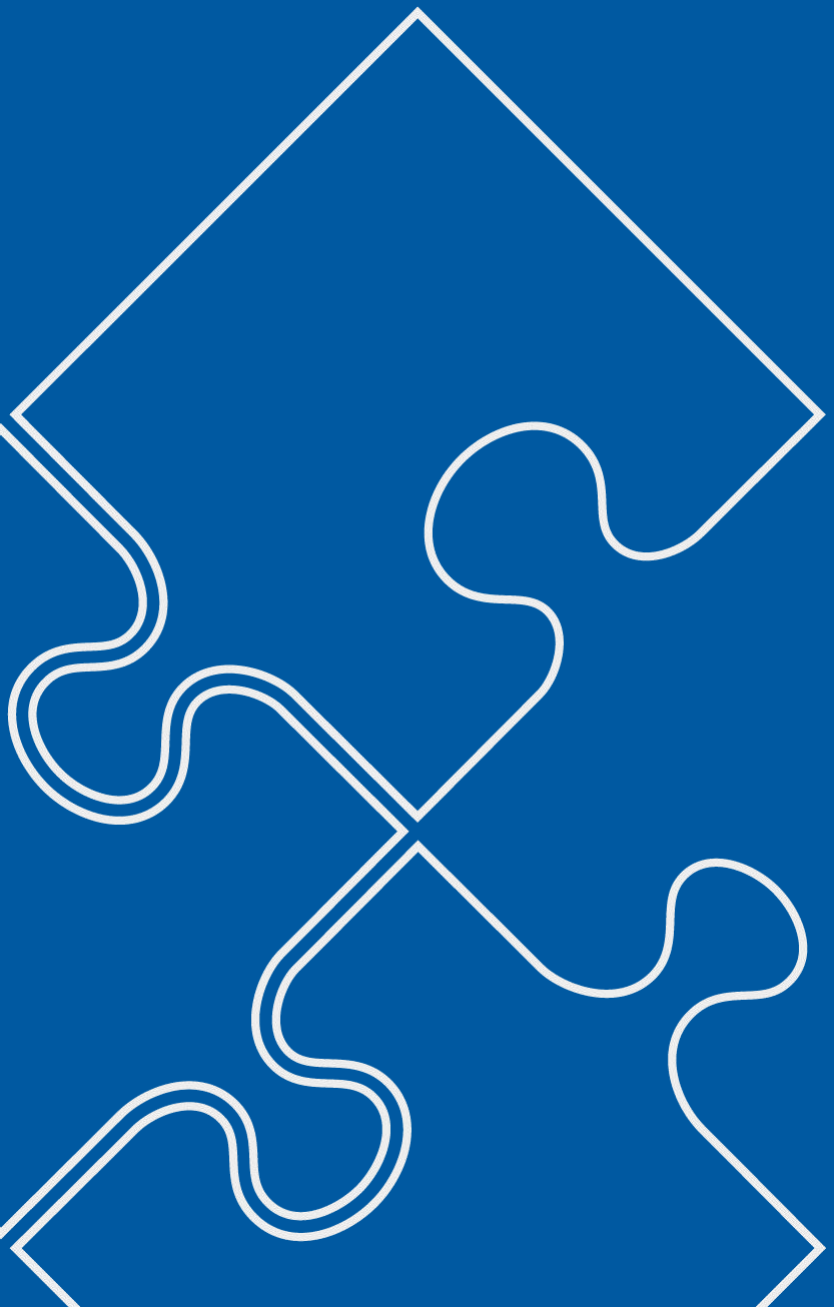
Figura 5 - Ponto de coleta de dados
Fonte: Autoria própria (2026).

```
linesample
{
    type                sets;
    libs                ("libsampling.so");
    enabled             true;
    writeControl        runTime;
    writeInterval       0.5;

    interpolationScheme cellPoint;
    setFormat           raw;
```

Figura 6 - Função de coleta de dados
Fonte: Autoria própria (2026).

- Dados coletados - séries temporais:
  - Velocidade;
  - Pressão;
  - Fração de água.



3

Método: Aprendizado de Máquina

Rede Neural Convolucional

A **Rede Neural Convolucional** utiliza filtros (*kernels*) para extrair hierarquias de características.

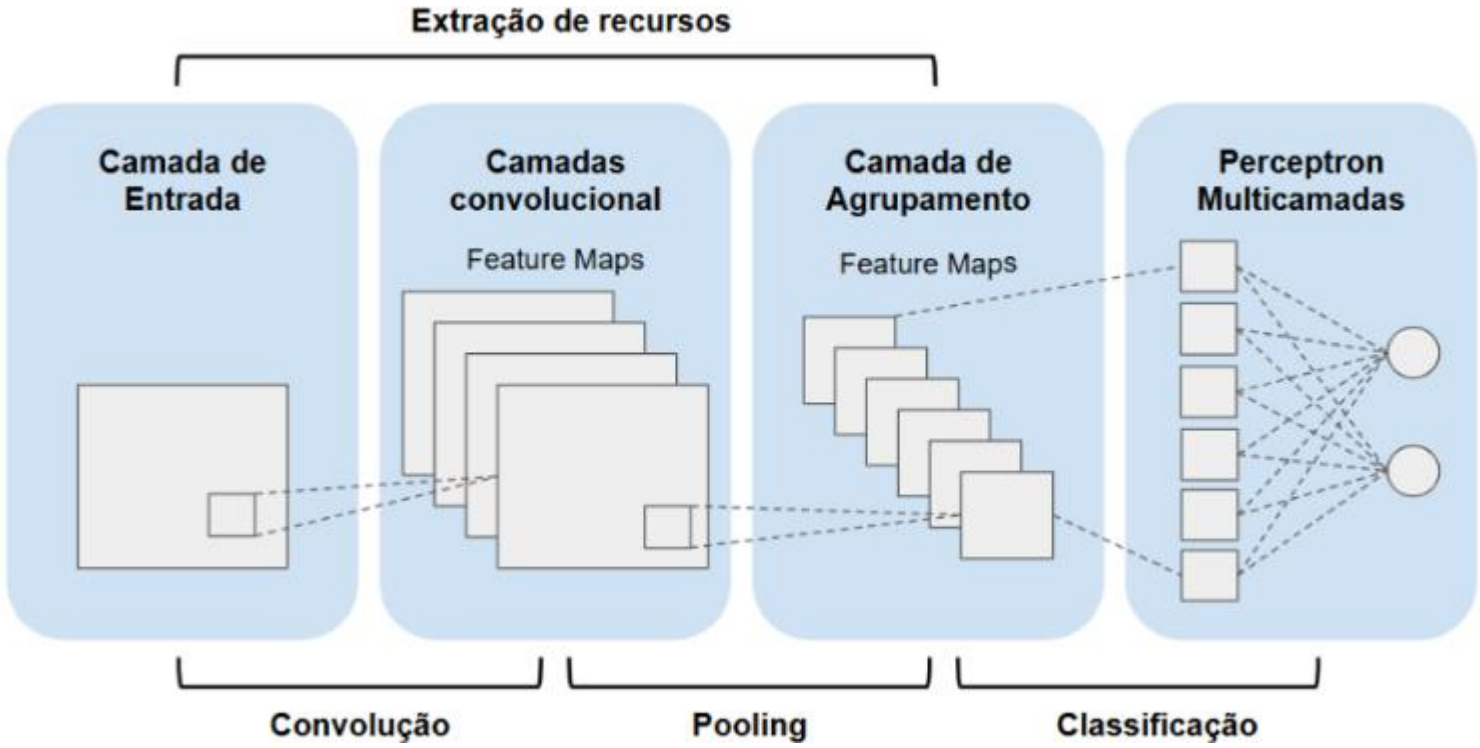


Figura 8 - Estrutura simplificada de uma rede neural convolucional.
Fonte: Adaptado de Barbosa et al. (2021)

Random Forest

O **Random Forest** constrói múltiplas árvores de decisão (que mapeiam escolhas e seus possíveis resultados) de forma independente, utilizando subconjuntos aleatórios dos dados e das variáveis. A predição final é obtida pela média (regressão) ou votação majoritária (classificação).

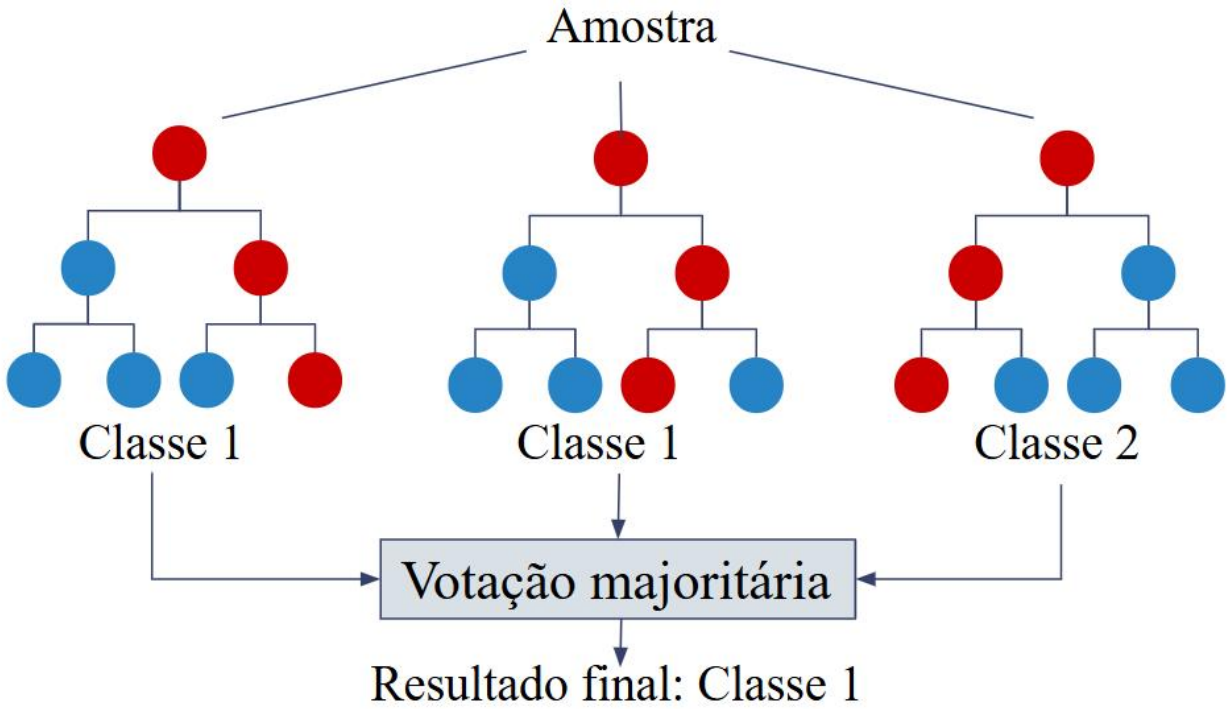


Figura 9 - Diagrama de funcionamento da Random Forest.
Fonte: Autoria própria (2026).

XG-Boost

A **XG-Boost** constrói árvores de decisão sequenciais, onde cada nova árvore corrige os erros da anterior.

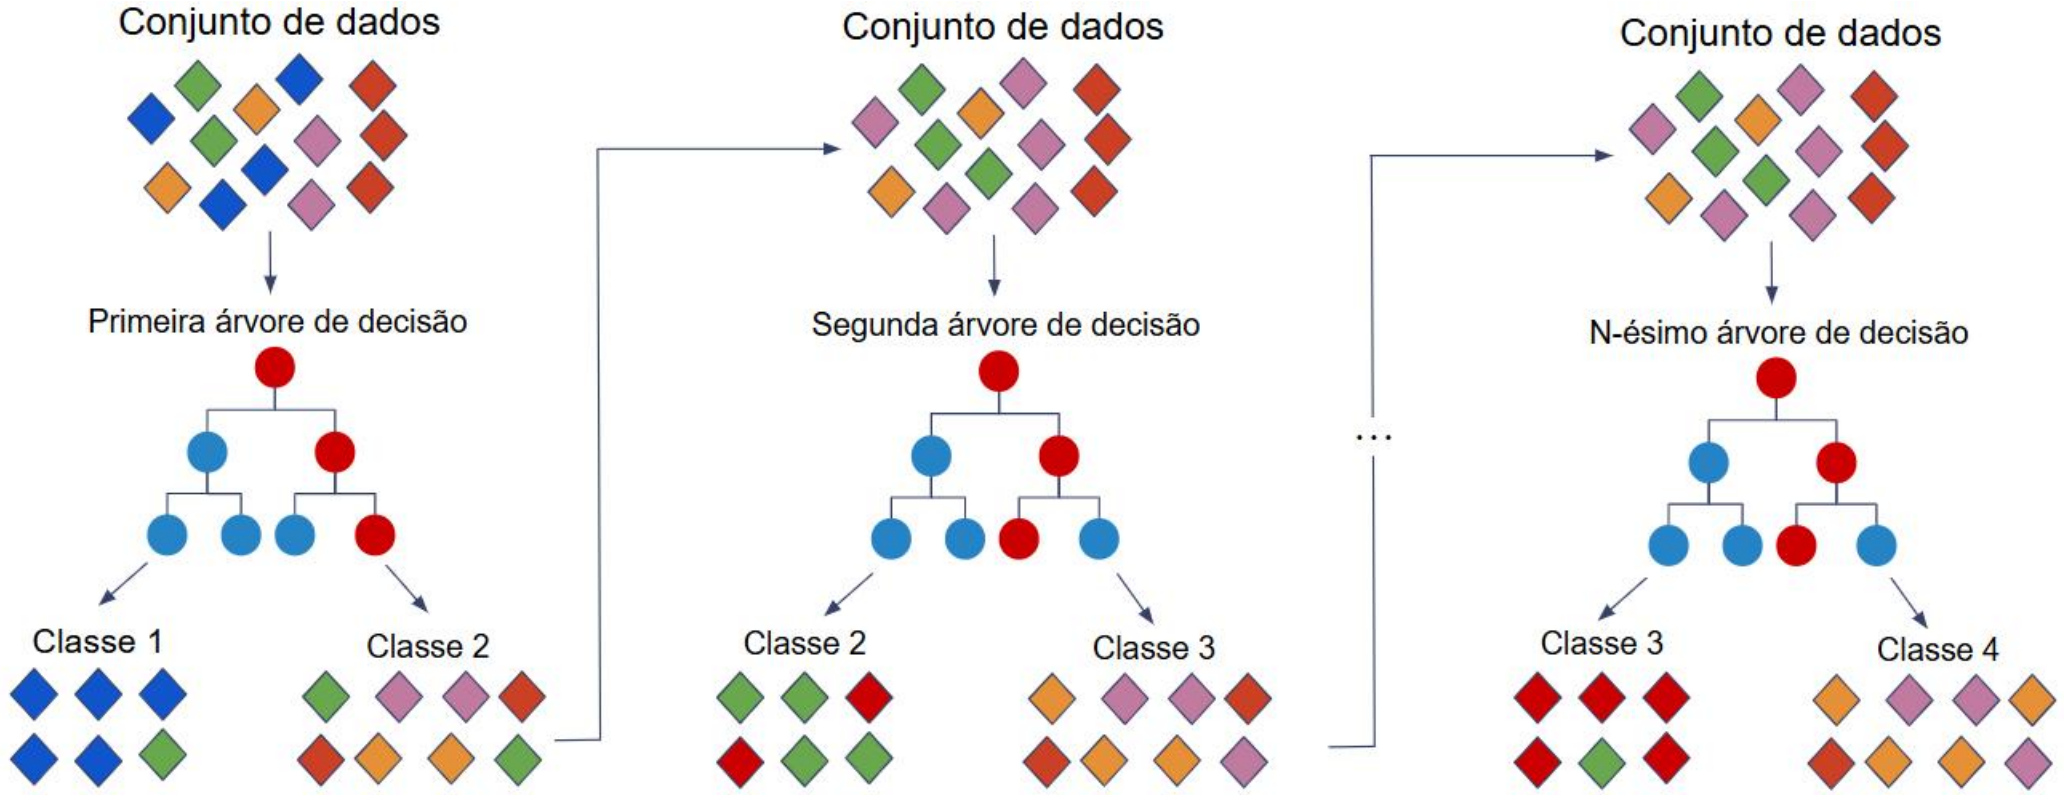


Figura 10 - Diagrama de funcionamento da XG-Boost.
Fonte: Autoria própria (2026).

K-Nearest Neighbors

A **K-Nearest Neighbors (KNN)** classifica um novo dado com base na proximidade geométrica em relação aos vizinhos.

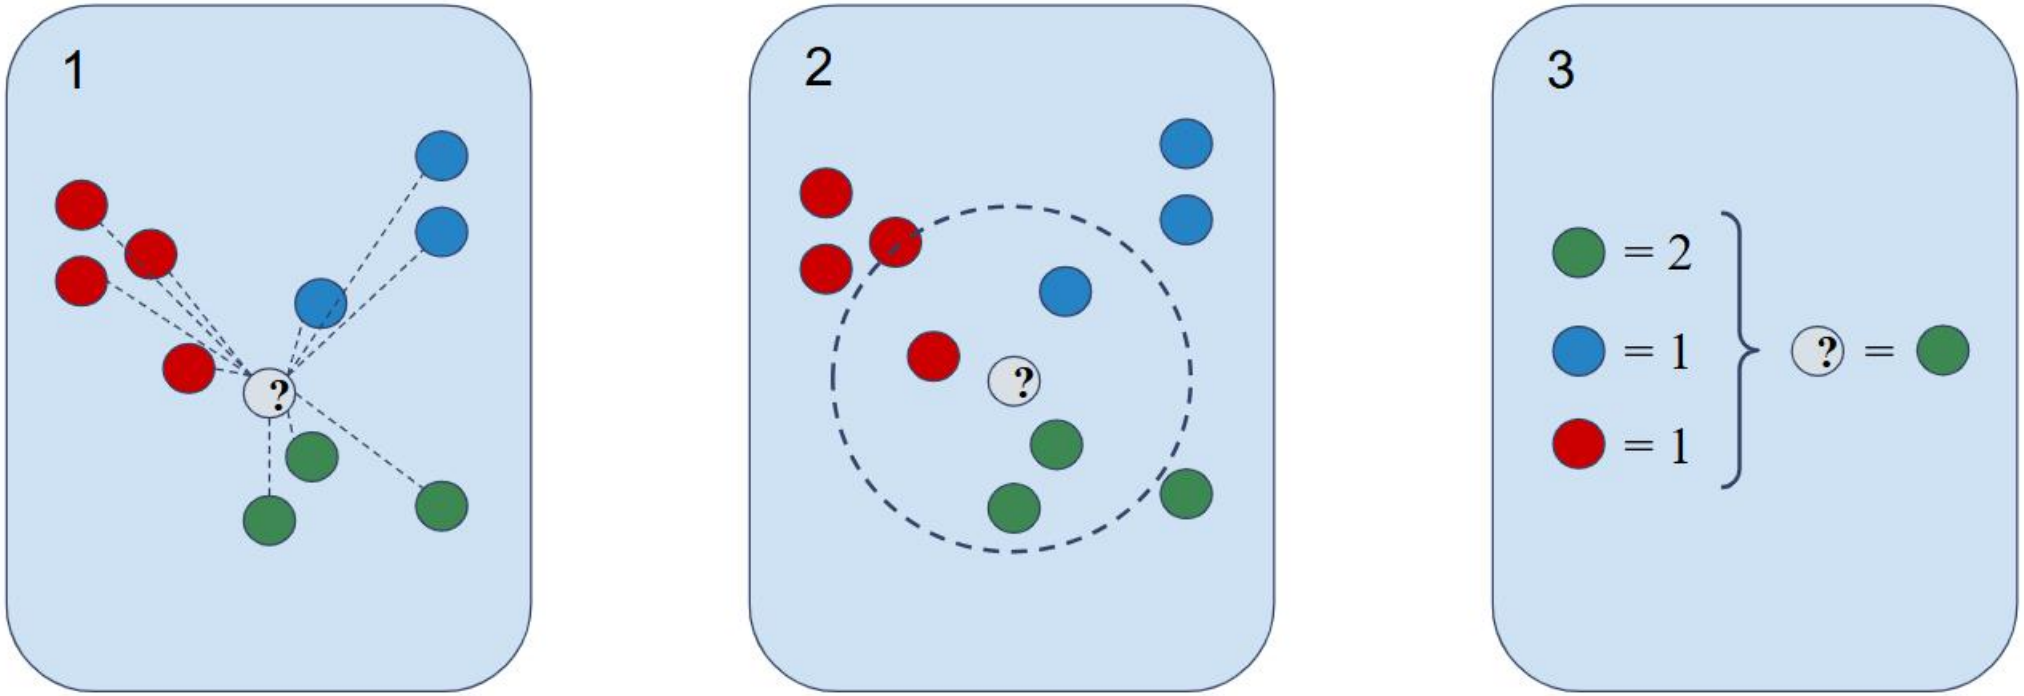


Figura 11 - Diagrama de funcionamento da K-Nearest Neighbors.
Fonte: Autoria própria (2026).

Máquinas de Vetores de Suporte

A **Máquinas de Vetores de Suporte (SVM)** busca o hiperplano ótimo que maximize a margem entre as classes.

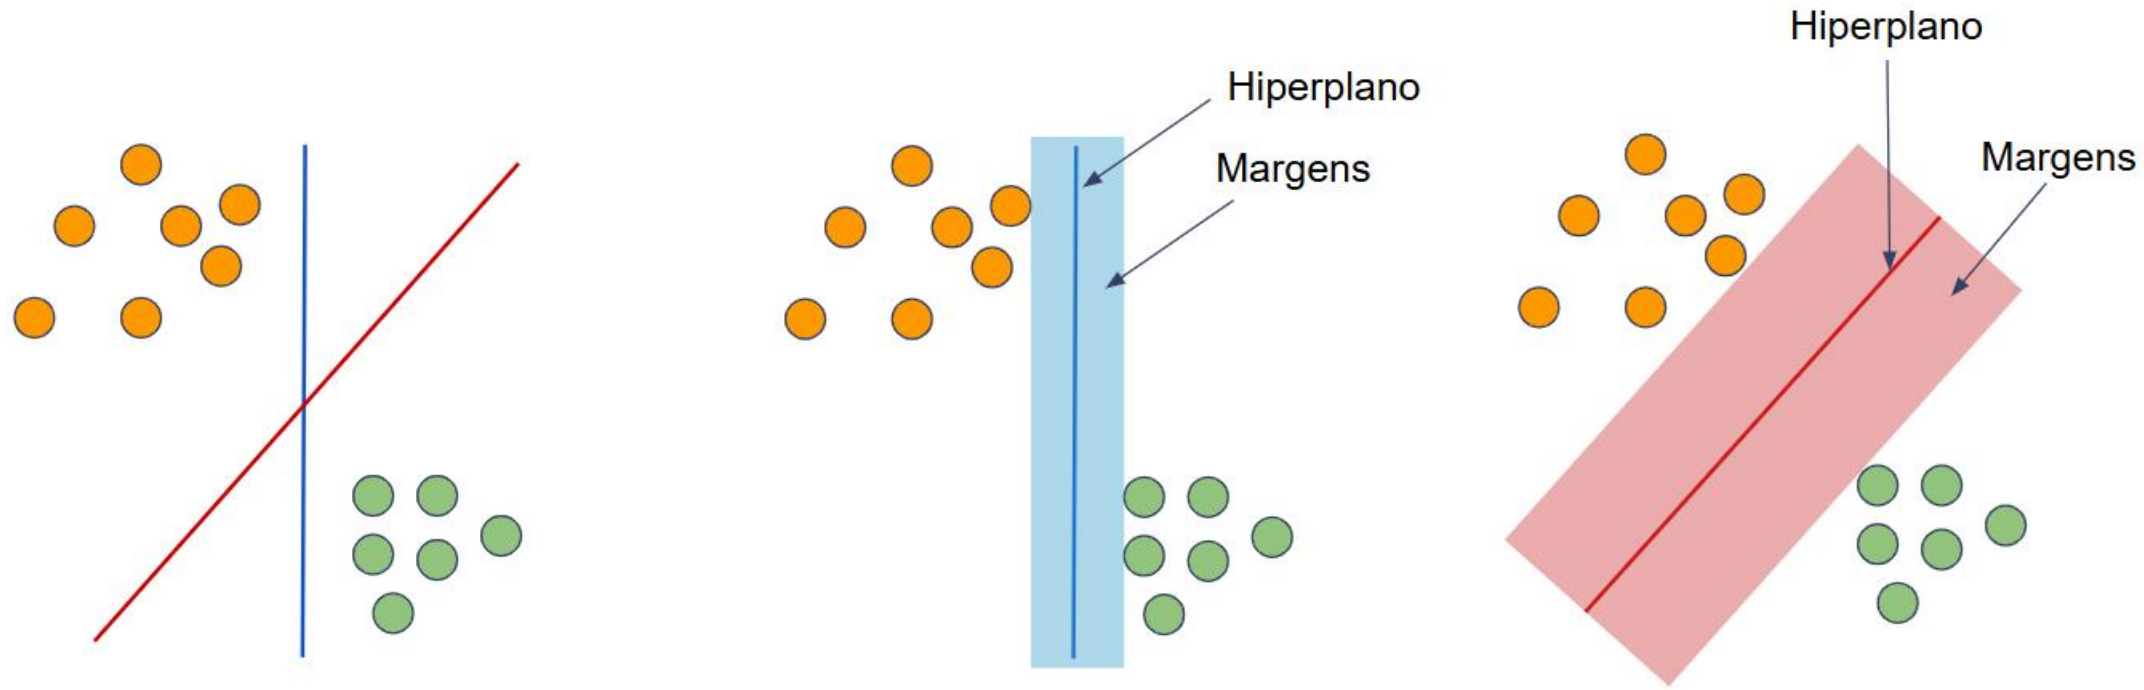


Figura 12 - Diagrama de funcionamento da Máquinas de Vetores de Suporte.
Fonte: Autoria própria (2026).

Técnicas de otimização: Função Objetivo

- Perda de entropia cruzada;
- Mede a diferença entre as probabilidades verdadeira e predita.

$$\min_{\theta} \mathcal{L}(\theta) = -\frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{c} y_{ij} \log f_j(x_i; \theta) \qquad (2)$$

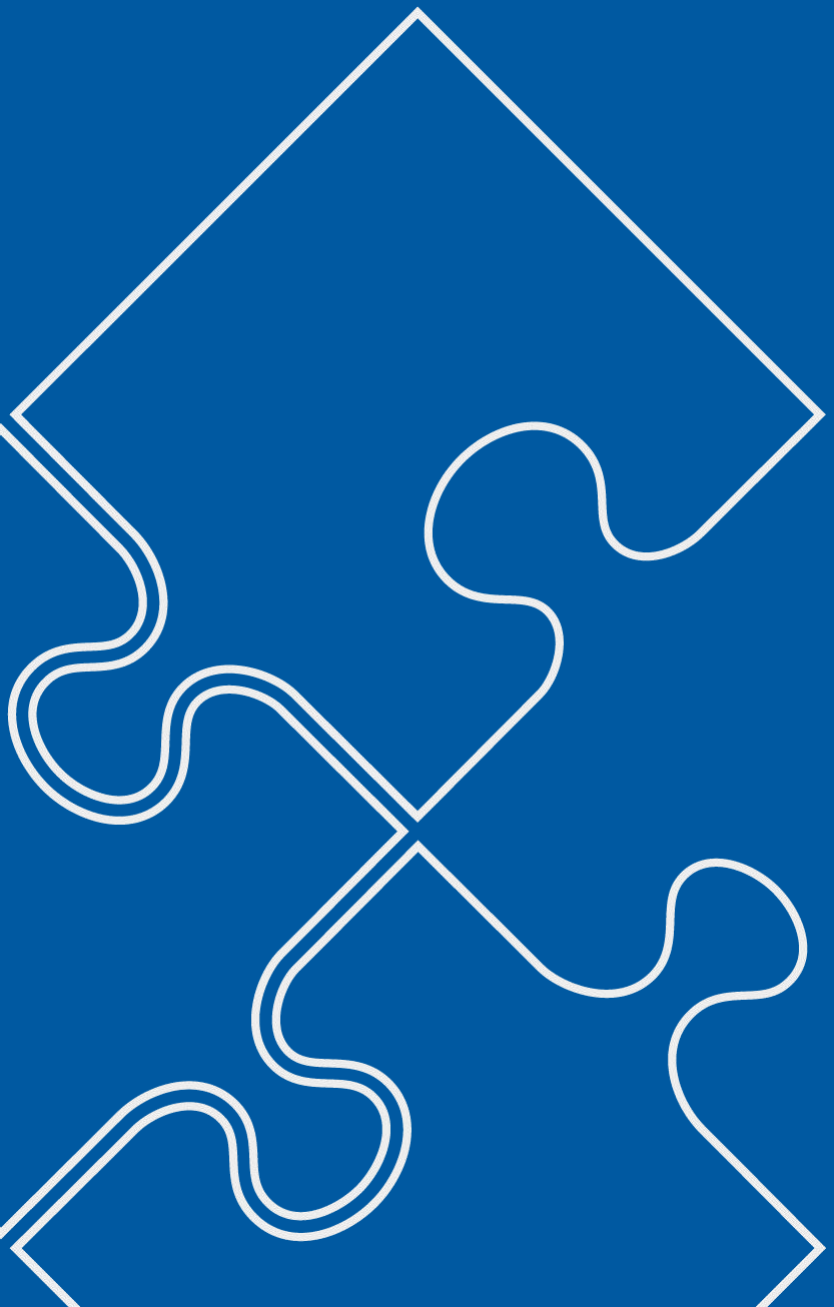
n - Número total de amostras;

y_{ij} - Rótulo verdadeiro da amostra;

$f_j(x_i; \theta)$ - Probabilidade predita pelo modelo para que a amostra *i* pertença à uma classe *j*, com base no conjunto de parâmetros do classificador θ.

Técnicas de otimização: Gradiente Descendente Estocástico

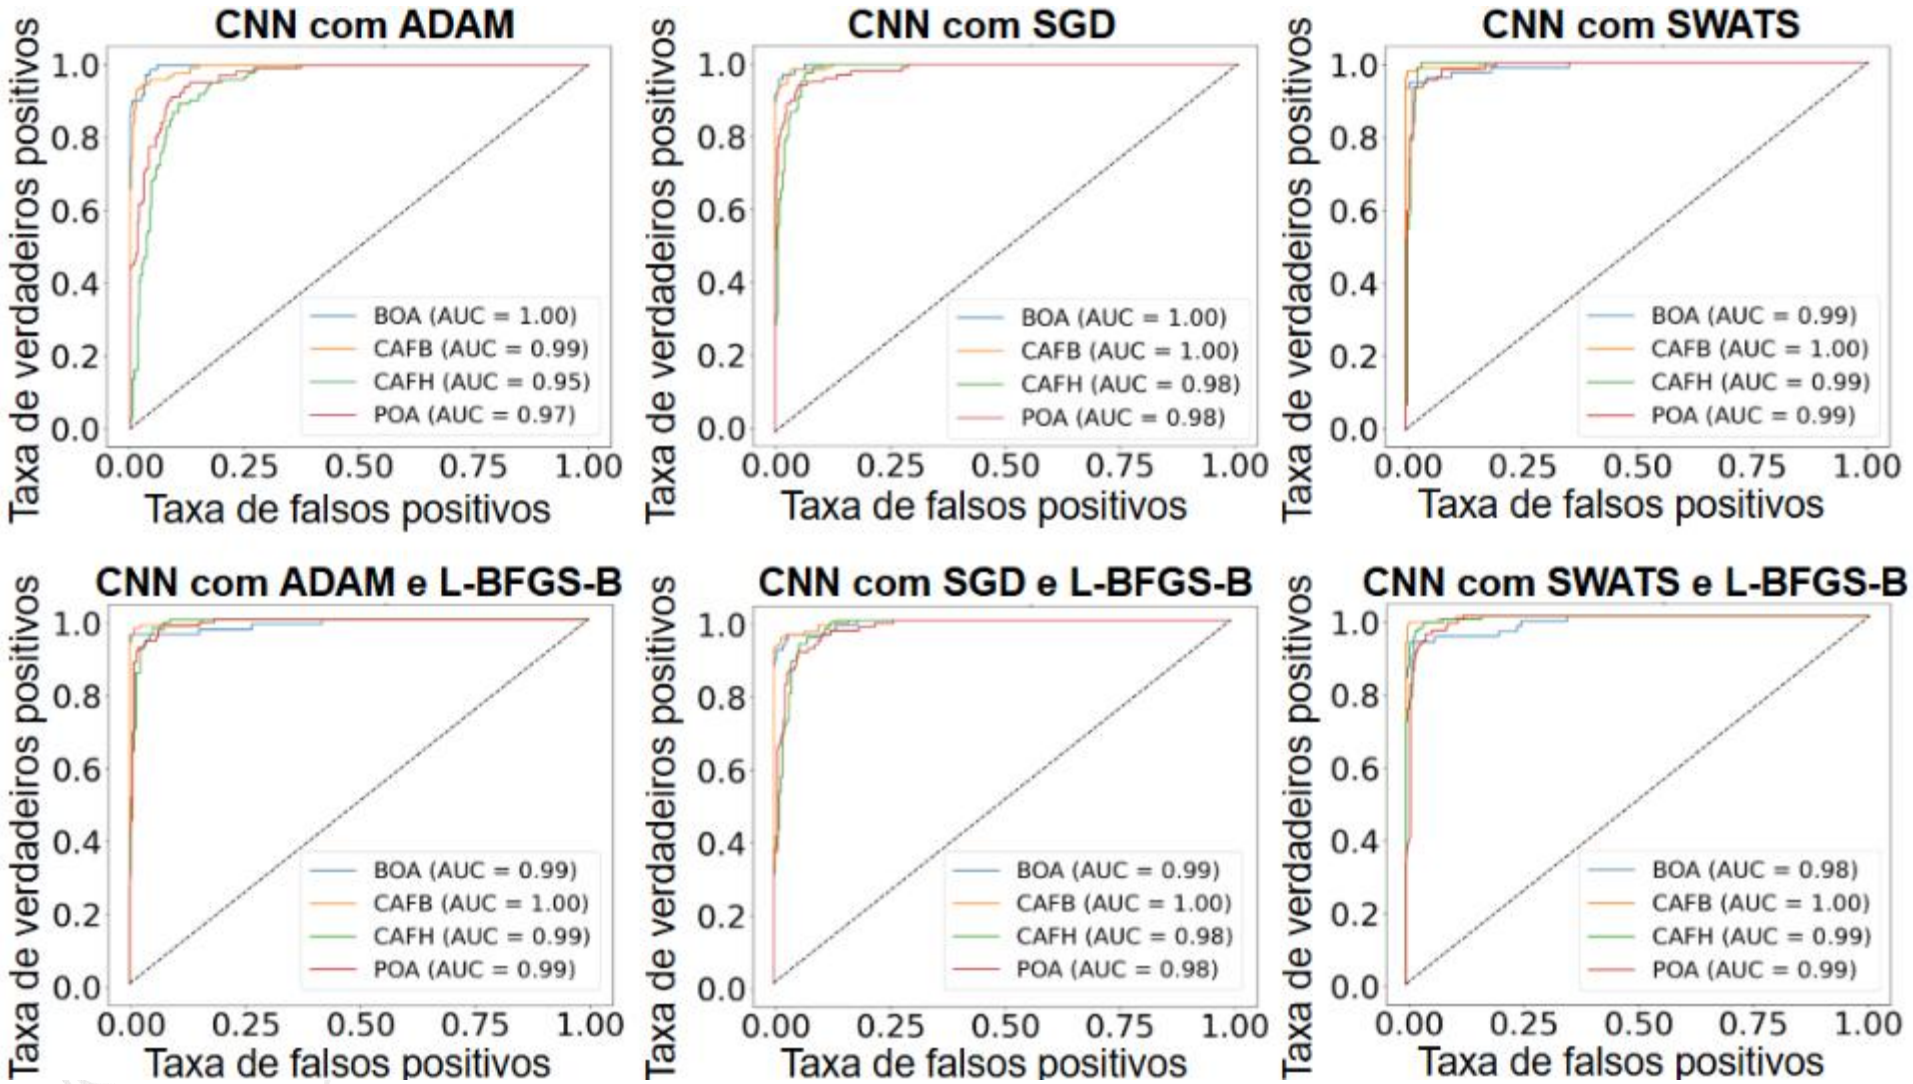
- **Gradiente Descendente Estocástico (SGD)**
  - Usa o gradiente da função de perda, calculado a partir de um lote de dados, para atualizar os hiperparâmetros do modelo;
  - Utiliza uma taxa de aprendizado.
- **Estimativa de Movimento Adaptável (ADAM)**
  - Usa a médias dos gradientes da função de perda e a variância não centrada dos gradientes da função de perda para atualizar os hiperparâmetros do modelo;
  - Adapta a taxa de aprendizado para cada parâmetro.
- **Otimizador Híbrido Switches from Adam to SGD (SWATS)**
  - 50 épocas iniciais com ADAM;
  - 50 épocas finais com SGD.
- **Otimizador L-BFGS-B**
  - Utiliza a aproximação da matriz Hessiana da função objetivo para estimar a curvatura da superfície de erro.



4

Resultados

Resultados: desempenho das técnicas de otimização aplicadas à CNN

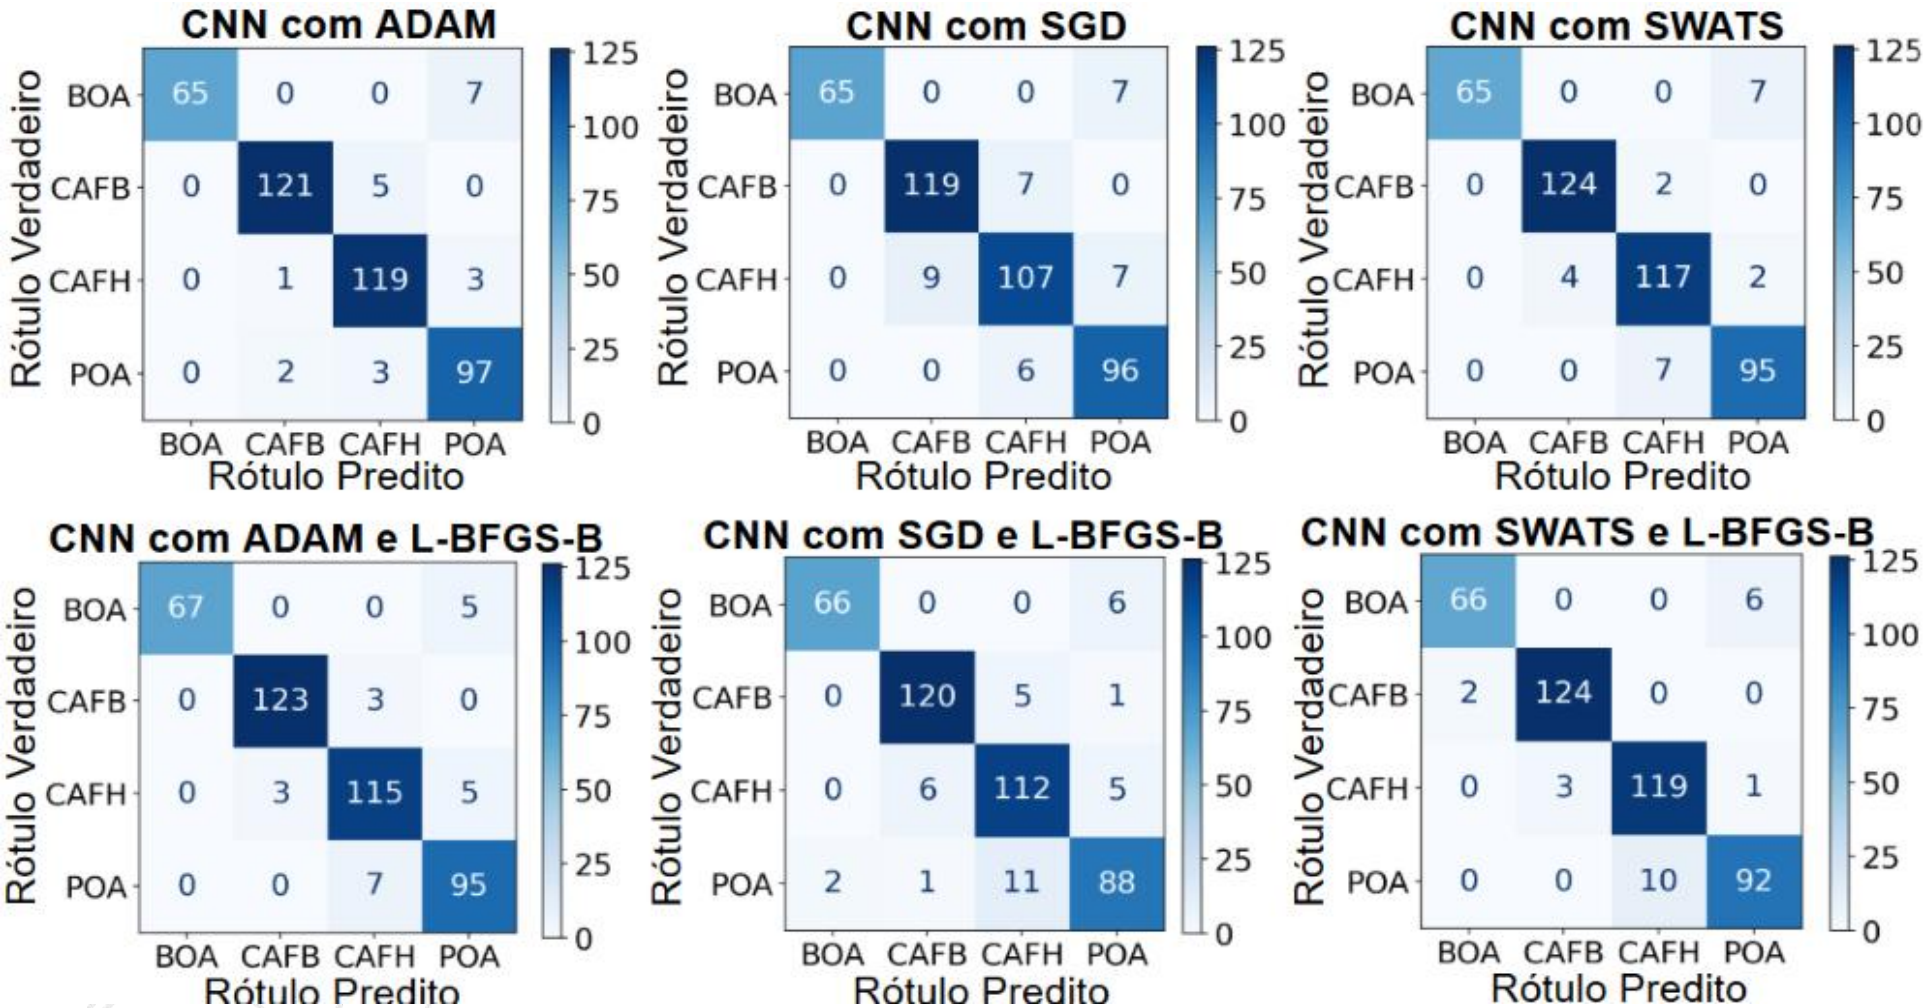


Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Figura 13 - Curvas ROC das técnicas de otimização aplicadas a CNN.
Fonte: Autoria própria (2026).

Resultados: desempenho das técnicas de otimização aplicadas à CNN



Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Figura 14 - Matrizes de confusão das técnicas de otimização aplicadas a CNN.
Fonte: Autoria própria (2026).

Resultados: desempenho das técnicas de otimização aplicadas à CNN

CNN com ADAM

Classe	Certo
BOA	90.28%
POA	95.10%
CAFB	96.03%
CAFH	96.75%

CNN com SGD

Classe	Certo
BOA	90.28%
POA	94.12%
CAFB	94.44%
CAFH	86.99%

CNN com SWATS

Classe	Certo
BOA	90.28%
POA	93.14%
CAFB	98.41%
CAFH	95.12%

CNN com ADAM e L-BFGS-B

Classe	Certo
BOA	93.05%
POA	93.14%
CAFB	97.62%
CAFH	93.49%

CNN com SGD e L-BFGS-B

Classe	Certo
BOA	91.67%
POA	86.27%
CAFB	95.24%
CAFH	91.06%

CNN com SWATS e L-BFGS-B

Classe	Certo
BOA	91.67%
POA	90.20%
CAFB	98.41%
CAFH	96.74%

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Figura 15 - Matrizes de confusão das técnicas de otimização aplicadas a CNN.
Fonte: Autoria própria (2026).

Resultados: desempenho das técnicas de otimização aplicadas à SVM

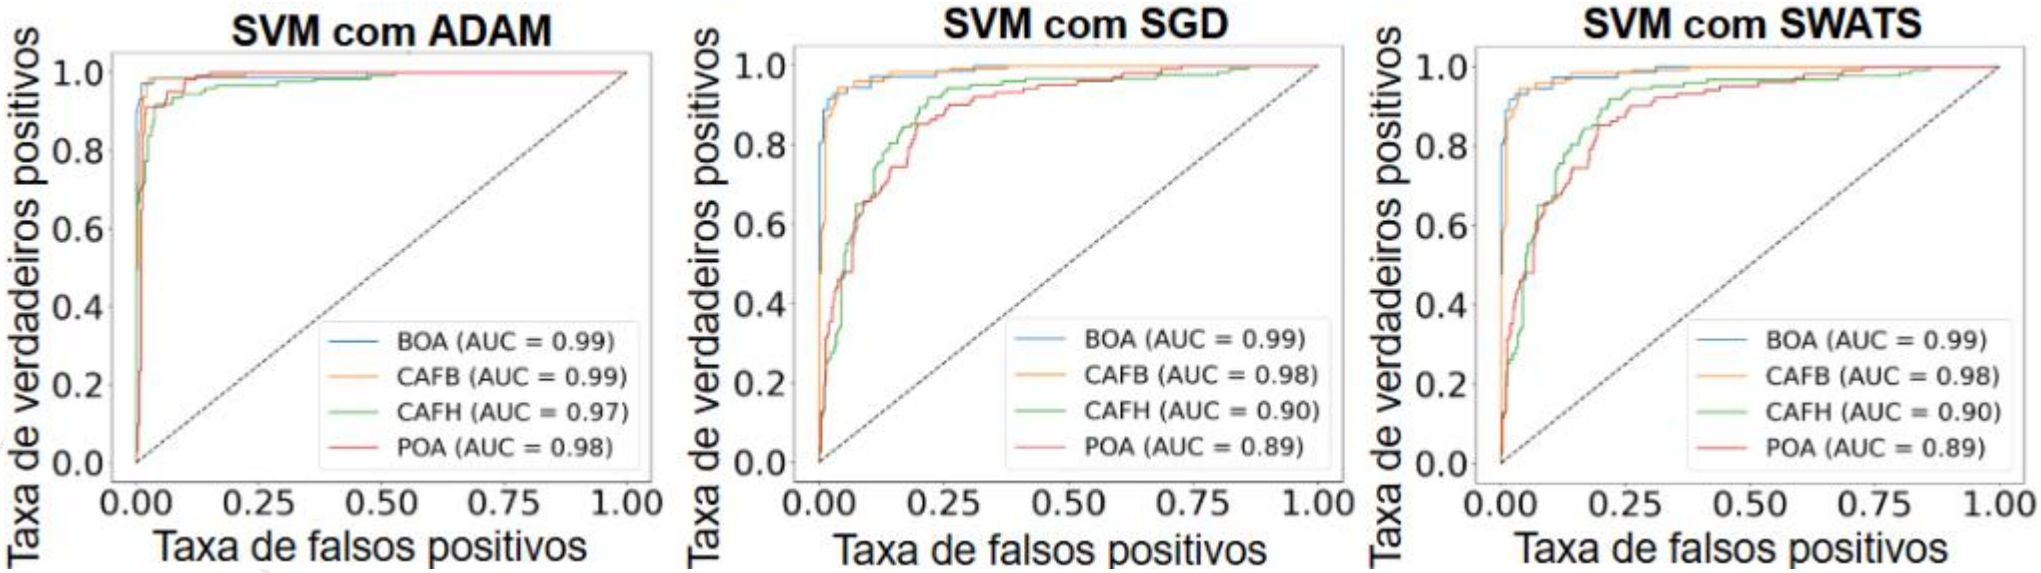


Figura 16 - Curvas ROC das técnicas de otimização aplicadas a SVM.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho das técnicas de otimização aplicadas à SVM

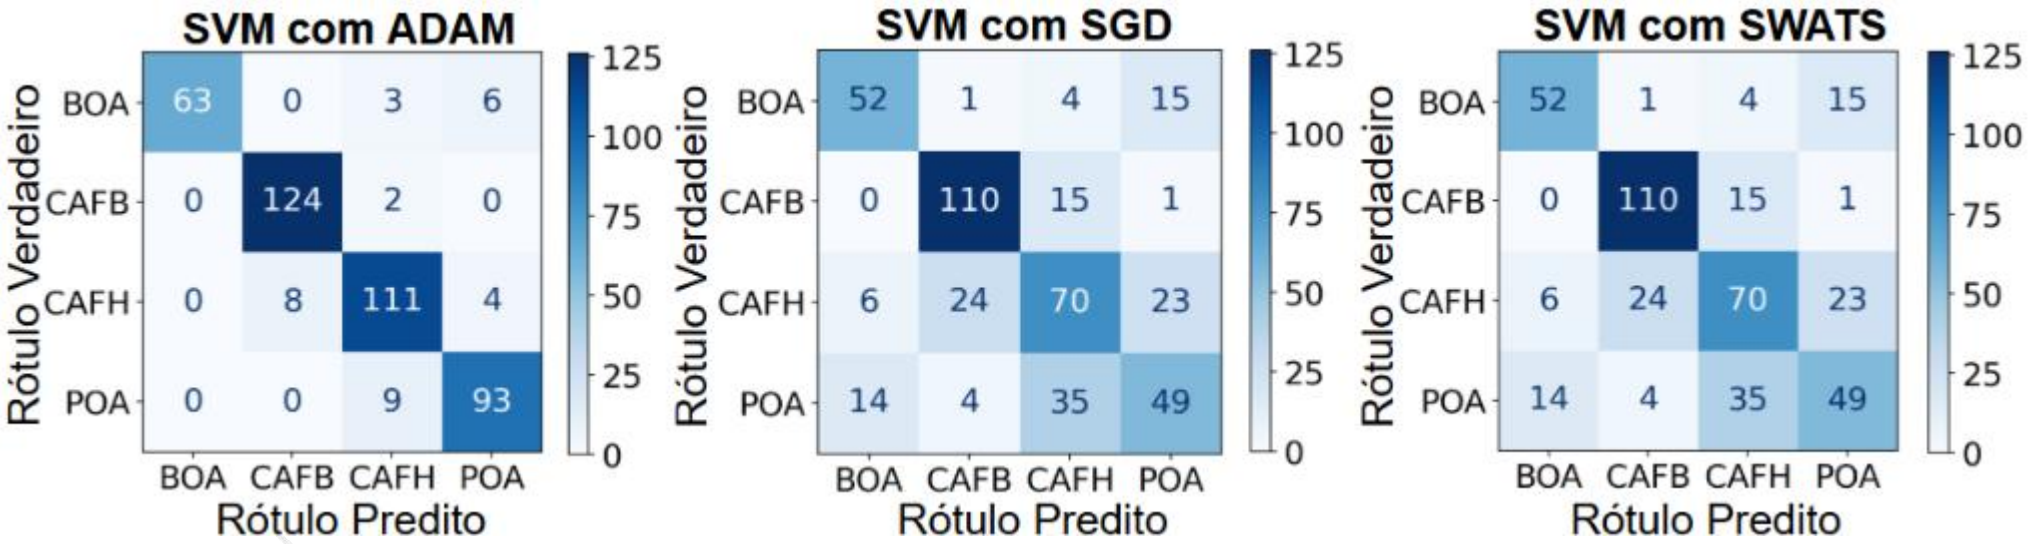


Figura 17 - Matrizes de confusão das técnicas de otimização aplicadas a SVM.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho das técnicas de otimização aplicadas à SVM

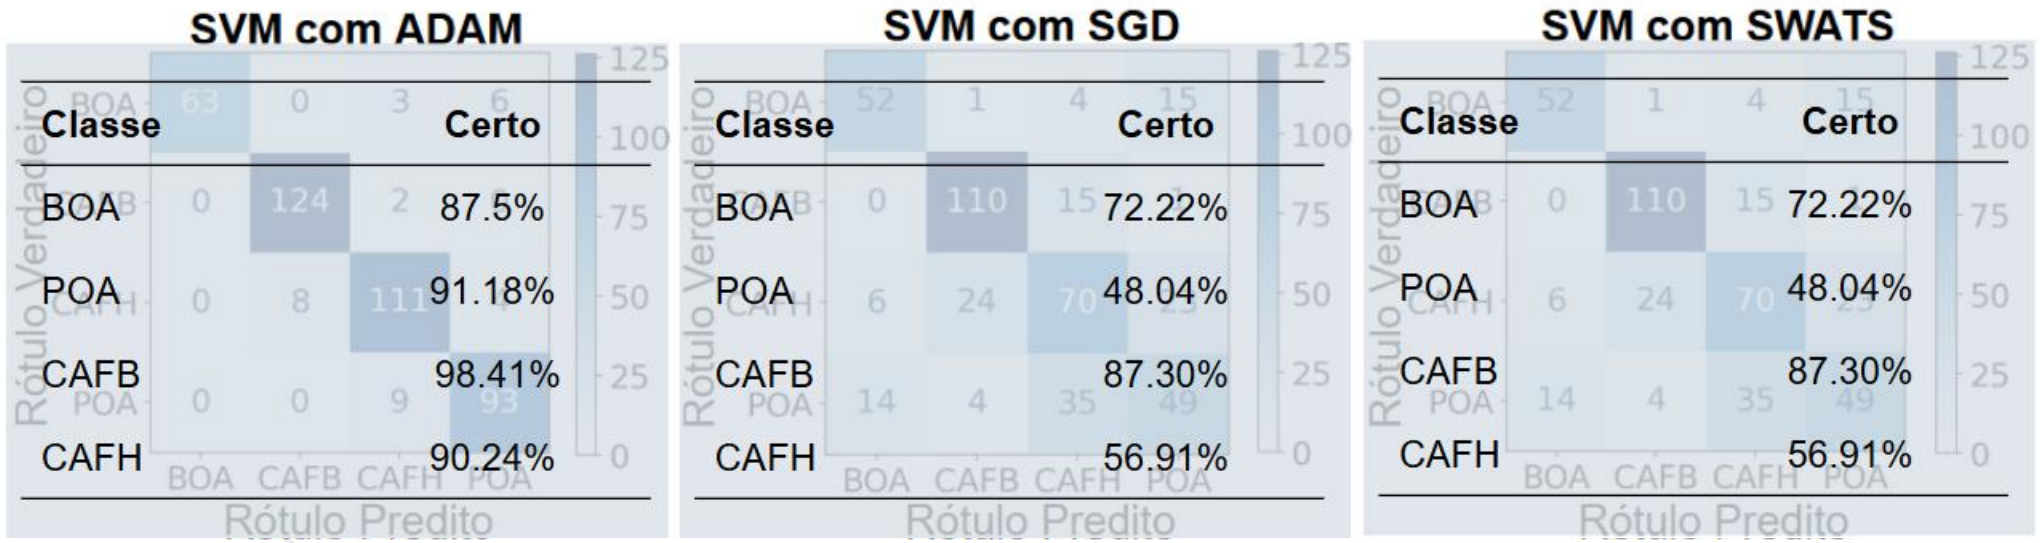


Figura 18 - Matrizes de confusão das técnicas de otimização aplicadas a SVM.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho dos modelos XG-Boost, Random Forest e KNN

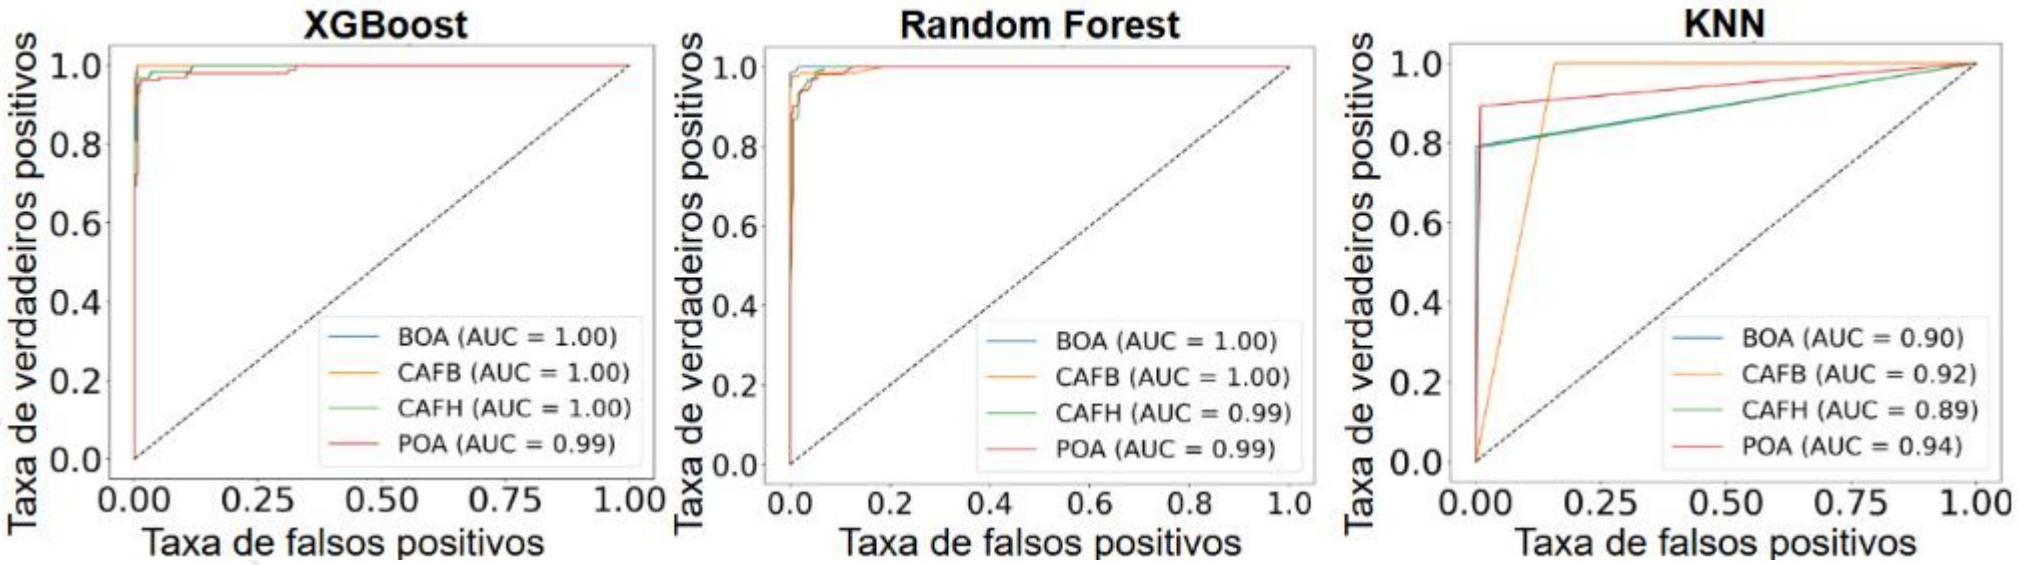


Figura 19 - Curvas ROC dos modelos de aprendizado: da Random Forest, XGBoost e K-Nearest Neighbors.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho dos modelos XG-Boost, Random Forest e KNN

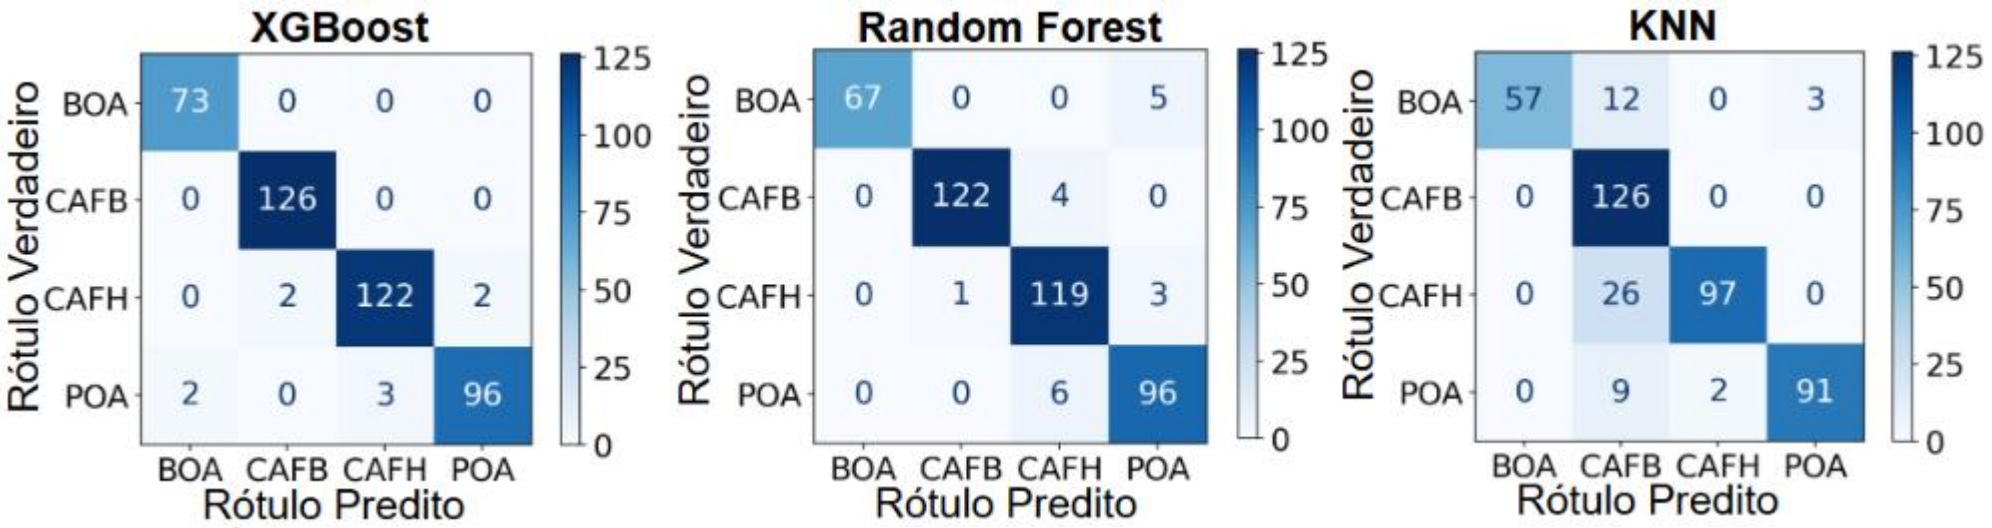


Figura 20 - Curvas ROC dos modelos de aprendizado: da Random Forest, XGBoost e K-Nearest Neighbors.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho dos modelos XG-Boost, Random Forest e KNN

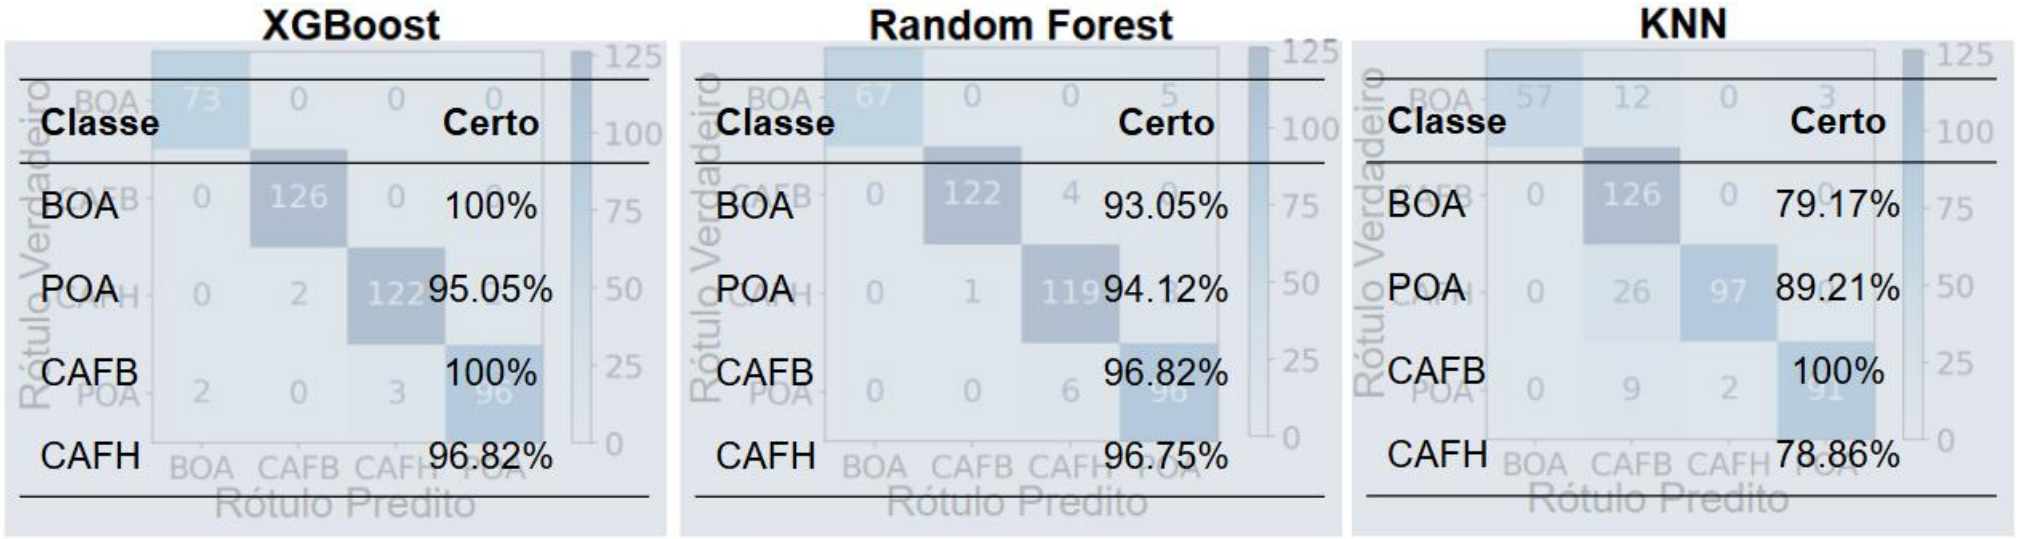


Figura 21 - Curvas ROC dos modelos de aprendizado: da Random Forest, XGBoost e K-Nearest Neighbors.
Fonte: Autoria própria (2026).

Glossário

BOA - Bolha de óleo em água
POA - Pistão de óleo em água
CAFB - *Core-annular flow* tipo bambu.
CAFH - *Core-annular flow* Helicoidal.

Resultados: desempenho dos modelos de aprendizado de máquina

Tabela 1 - Métricas de desempenho.

Modelo de Aprendizado	Acurácia	Precisão	Recall	F1-score
Random Forest	95%	96%	95%	96%
Rede Neural Convolucional com ADAM	95%	95%	95%	95%
Rede Neural Convolucional com ADAM e L-BFGS-B	95%	95%	95%	95%
Rede Neural Convolucional com SGD	91%	92%	91%	92%
Rede Neural Convolucional com SGD e L-BFGS-B	91%	91%	91%	91%
Rede Neural Convolucional com SWATS	95%	95%	95%	95%
Rede Neural Convolucional com SWATS e L-BFGS-B	91%	91%	91%	91%
XGBoost	98%	98%	98%	98%
K-Nearest Neighbors	88%	92%	87%	88%
Máquinas de Vetores de Suporte com ADAM	92%	93%	92%	92%
Máquinas de Vetores de Suporte com SGD	81%	81%	81%	81%
Máquinas de Vetores de Suporte com SWATS	81%	81%	81%	81%

Fonte: Autoria própria (2026).

Resultados: custo computacional

Tabela 2 - Tempo de execução dos modelos.

Modelo de Aprendizado	Tempo de Execução
Random Forest	36.59s
Rede Neural Convolucional Com ADAM	473.58s
Rede Neural Convolucional com ADAM e L-BFGS-B	726.89s
Rede Neural Convolucional com SGD	191.89s
Rede Neural Convolucional Com SGD e L-BFGS-B	571.60s
Rede Neural Convolucional com SWATS	755.92s
Rede Neural Convolucional Com SWATS e L-BFGS-B	1058.34s
XGBoost	41.50s
K-Nearest Neighbors	39.22s
Máquinas de Vetores de Suporte com ADAM	12.31s
Máquinas de Vetores de Suporte com SGD	19.13s
Máquinas de Vetores de Suporte com SWATS	52.56s

Fonte: Autoria própria (2026).

Tabela 3 - Especificações de hardware.

Modelo do hardware	Nitro ANV15-51
Memória RAM	16 GB
Processador	Intel Core i7 de 13ª geração
Placa de vídeo	NVIDIA GeForce RTX 3050 6GB
Nome do sistema operacional	Windows 11 Home
Tipo do sistema Operacional	64 bits

Fonte: Autoria própria (2026).

Máquinas de Vetores de Suporte com ADAM	92%	93%	92%	92%

Considerações Finais

- **Modelagem CFD:**
  - Reprodução dos padrões BOA, CAFB, CAFH e POA com elevada concordância qualitativa com a literatura;
  - Geração de dados sintéticos representativos para treinamento dos modelos.
- **Desempenho dos modelos de aprendizado de máquina:**
  - XGBoost: melhor equilíbrio entre acurácia e custo computacional;
  - Random Forest: segundo melhor desempenho;
  - CNN: elevada capacidade de classificação, porém maior custo computacional;
  - SVM com ADAM: eficiente computacionalmente, com menor capacidade de generalização;
  - KNN: desempenho inferior aos demais modelos.

Considerações Finais

- **Contribuições:**
  - Demonstrou a viabilidade da integração entre CFD e aprendizado de máquina para classificação automática de padrões de escoamento;
  - Evidenciou o potencial de dados sintéticos para treinamento de modelos inteligentes;
  - Forneceu uma base para sistemas de monitoramento e controle inteligente no transporte de óleos pesados.

Trabalhos Futuros

- Como continuidade desta pesquisa, recomenda-se a realização de estudos experimentais para validação quantitativa dos resultados numéricos obtidos.

Agradecimentos

• Agradeço o apoio financeiro da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), através do Programa de Recursos Humanos em Descarbonização e Transformação Digital para Indústria de Petróleo e Gás da Universidade Federal da Bahia (PRH 41/UFBA), sob a gestão da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo nº 2025/03627-1.



Camila Oliveira dos Santos Borges

Dados para contato

Email: camila.b2190@gmail.com

Linkedin: Camila Borges

Referências

ACTION, C. C. 14: Recommendations on the use of cfd in predicting pedestrian wind environment. Bruxelas: Cost, 2004.

AKUJUOBI, C. Wavelets and Wavelet Transform Systems and Their Applica tions: A Digital Signal Processing Approach. Springer International Publishing, 2022. ISBN 9783030875282. Disponível em: https://books.google.com.br/books?id=oJxcEAAAQBAJ.

ALEXANDRIDIS, A. K.; ZAPRANIS, A. D. Wavelet neural networks: with applications in financial engineering, chaos, and classification. [S.l.]: John Wiley & Sons, 2014.

ALSEHLI, M. et al. Insights into water-lubricated transport of heavy and extra-heavy oils: Application of cfd, rsm, and metaheuristic optimized machine learning models. Fuel, v. 374, p. 132431, jul 2024.

AYUBA, N. et al. 3d interface analysis of velocity, volume ratio, and reynolds number effects on core annular flow (caf). Experimental and Computational Multiphase Flow, Springer, p. 1–9, 2022.

BAHIA, M. F. DETERMINAÇÃO DE COEFICIENTES HIDRODINÂMICOS EM MA NIFOLDS SUBMARINOS. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2024.

BALCILAR et al. Artificial neural network techniques for the determination of condensa tion heat transfer characteristics during downward annular flow of r134a inside a vertical smooth tube. International Communications in Heat and Mass Transfer, Elsevier, v. 38, n. 1, p. 75–84, 2011.

BARINO,F.O.; SANTOS,A.B.dos. Rede neural convolucional 1d aplicada à previsão da vazão no rio madeira. XXXVIII SIMPÓSIO BRASILEIRO DE TELECOMUNICAçÕES E PROCESSAMENTO DE SINAIS-SBrT 2020, p. 32, 2020.

BAUMERT,H.etal.Marine Turbulence: Theories, Observations, and Models. Cambridge University Press, 2005. ISBN 9780521837897. Disponível em: https://books.google.com.br/books?id=HVqbdXI29i0C .

BEAM, R. M.; WARMING, R. F. Implicit Numerical Methods for the Compressible Navier-Stokes and Euler Equations. Rhode Saint Genese, Belgium: [s.n.], 1982. Von Kar man Institute Lecture Series.

BENEVIDES, S. Transporte de óleos pesados via técnica core–flow em dutos curvados: Análise da eficiência energética e da perda de carga. Petroleum, v. 10, p. 399–410, 2024

Referências

BERGMAN, T. L.; LAVINE, A. S. Fundamentos de Transferência de Calor e de Massa. 8. ed. Rio de Janeiro: Grupo GEN, 2019.

BISSANTZ, J. et al. Application of dense neural networks for manifold-based modeling of f lame-wall interactions. Applications in Energy and Combustion Science, Elsevier, v. 13, p. 100113, 2023.

BREIMAN, L. Random forests. Machine learning, Springer, v. 45, n. 1, p. 5–32, 2001.

ÇENGEL, Y.; CIMBALA, J. Mecânica dos fluidos: fundamentos e aplicações. McGraw Hill, 2007. ISBN 9788586804588. Disponível em: https://books.google.com.br/books?id=utWVPgAACAAJ.

CHENG, C. et al. A convolutional neural network-based method for distinguishing the f low patterns of gas-liquid two-phase flow in the annulus. Processes, MDPI, v. 12, n. 11, p. 2596, 2024.

CISCO, L. A. et al. Numerical analysis of the available power in an overtopping wave energy converter subjected to a sea state of the coastal region of tramandaí, brazil. Fluids, MDPI, v. 7, n. 11, p. 359, 2022.

COELHO, N. M. D. A. et al. Energy savings on heavy oil transportation through core annular flow pattern: An experimental approach. International Journal of Multiphase Flow, Elsevier, v. 122, p. 103127, 2020.

DEREICH, S.; JENTZEN, A.; RIEKERT, A. Averaged adam accelerates stochastic op timization in the training of deep neural network approximations for partial differential equation and optimal control problems. arXiv preprint arXiv:2501.06081, 2025.

DESAMALA, A. B. et al. Prediction of oil-water flow patterns, radial distribution of volume fraction, pressure and velocity during separated flows in horizontal pipe. Journal of Hydrodynamics, Springer, v. 28, n. 4, p. 658–668, 2016.

DOCUMENTATION, P. docs. python. org/3. 2024.

FERREIRA, P. Aprendizado de máquina. Editora Senac São Paulo, 2024. (Série Univer sitária). ISBN 9788539644124. Disponível em: https://books.google.com.br/books?id=52syEQAAQBAJ

FERREIRA, P. N. Título do Livro. [S.l.]: Editora Senac São Paulo, 2024. Livro digital, 156 páginas. Publicado em 19 de novembro de 2024. ISBN 9788539644124..

Referências

FERZIGER, J. H. et al. Computational methods for fluid dynamics. [S.l.]: springer, 2019. 6 e 294-296 p.

FILHO, G. H. P.; SARMENTO, A. G. B. d. L. Simulação numérica do transporte de óleos pesados de alta viscosidade em risers submersos. In: Anais do 5º Congresso Brasileiro de P&D em Petróleo e Gás. Fortaleza, CE: Associação Brasileira de P&D em Petróleo e Gás (ABPG), 2009.

FILHO, O. Inteligência artificial e aprendizagem de máquina: aspectos teóricos e aplica ções. Editora Blucher, 2023. ISBN 9786555066166. Disponível em: FILHO, O. Inteligência artificial e aprendizagem de máquina: aspectos teóricos e aplica ções. Editora Blucher, 2023. ISBN 9786555066166. Disponível em: https://books.google.com.br/books?id=km-HEQAAQBAJ.

FILIPIAK, M. Mesh generation. Edinburgh parallel computing centre, the University of Edinburgh, Edinburgh, 1996.

FRANCE, É. de. Code_aster, analysis of structures and thermomechanics for studies & research. Open source on www. code-aster. com, 1989.

FREITAS, C. M.; ANTONIETTI, A. J. Análise dos modelos de turbulência k-, k-ω e sst no escoamento cruzado sobre um cilindro. Revista Perspectiva, v. 44, n. 166, p. 19–30, 2020.

FRISCH, U.; KOLMOGOROV, A. N. Turbulence: the legacy of AN Kolmogorov. [S.l.]: Cambridge university press, 1995.

GAOetal. Numerical study of stratified oil-water two-phase turbulent flow in a horizontal tube. INTERNATIONAL JOURNAL OF HEAT AND MASS TRANSFER, v. 46, n. 4, p. 749–754, FEB 2003. ISSN 0017-9310.

GENUER,R.; POGGI, J.-M. Random forests. In: Random forests with R. [S.l.]: Springer, 2020. p. 33–55.

GIL, C. A sociedade do conhecimento e suas tecnologias: estudos em Ciências Exatas e Engenharias: Volume 1. Editora Dialética, 2022. ISBN 9786525238487. Disponível em: https://books.google.com.br/books?id=ORxtEAAAQBAJ.

GOMAA, S.; SALEM, K. G. Enhanced heavy and extra heavy oil recovery: Current status and new trends. Petroleum, v. 10, n. 3, p. 399–410, 2024.

GONÇALVES, A. R. Máquina de vetores suporte. Acesso em, v. 21, 2010.

GREENSHIELDS,C.J.etal.Openfoamuserguide. OpenFOAM Foundation Ltd, version, v. 3, n. 1, p. 47, 2015.GUO, L. et al. Identification of boiling two-phase flow regimes based on two kinds of neural networks. Applied Mechanics and Materials, Trans Tech Publ, v. 29, p. 54–60, 2010.

Referências

HANAFIZADEH, P. et al. Experimental investigation of oil–water two phase flow regime in an inclined pipe. Journal of Petroleum Science and Engineering, Elsevier, v. 136, p. 12–22, 2015.

HAYKIN, S. Redes neurais: princípios e prática. [S.l.]: Bookman Editora, 2001.

JADIDI et al. Analysis of core annular flow behavior of water-lubricated heavy crude oil transport. Fluids, MDPI, v. 8, n. 10, p. 267, 2023.

JASAK, H. Error analysis and estimation for the finite volume method with applications to fluid flows. Direct, 1996.

JIANG, F. et al. Numerical simulation on oil–water annular flow through the π bend. Industrial & Engineering Chemistry Research, ACS Publications, v. 53, n. 19, p. 8235 8244, 2014.

JIANG, W. et al. Numerical study of swirl core-annular flow and factors influencing pressure drop in vertical pipelines for oil-water two-phase flow. Geoenergy Science and Engineering, Elsevier, v. 244, p. 213416, 2025.

JOHN, D.; ANDERSON, J. Computational fluid dynamics: the basics with applications. Mechanical engineering series, McGraw Hill Education New York, p. 261–262, 1995.

JOSEPH et al. Instability of the flow of two immiscible liquids with different viscosities in a pipe. Journal of Fluid Mechanics, Cambridge University Press, v. 141, p. 309–317, 1984.

JR, D. M.; MORAES, M. Laboratório de operações unitárias i. exemplos de projetos, problemas resolvidos, questões resolvidas de concursos públicos, ensaios de bancada de unidades industriais. Santos, Ed. dos autores, 2011.

KAABAR, S. Aprendizado profundo para finanças Criando modelos de máquina e apren dizado profundo para negociação em Python. jideon francisco marques, 2024. Disponível em: https://books.google.com.br/books?id=nPvtEAAAQBAJ.

KAISER, G.; HUDGINS, L. H. A friendly guide to wavelets. [S.l.]: Springer, 1994. v. 300.

KESKAR, N. S.; SOCHER, R. Improving generalization performance by switching from adam to sgd. arXiv preprint arXiv:1712.07628, 2017.

KINGMA, D. P. Adam: A method for stochastic optimization. arXiv preprint ar Xiv:1412.6980, 2014.

Referências

KRAMER, O. Dimensionality Reduction with Unsupervised Nearest Neighbors. Springer Berlin Heidelberg, 2013. (Intelligent Systems Reference Library). ISBN 9783642386527. Disponível em: https://books.google.com.br/books?id=pU4_AAAAQBAJ.

LANDRO, N.; GALLO, I.; GRASSA, R. L. Mixing adam and sgd: A combined optimi zation method. arXiv preprint arXiv:2011.08042, 2020.

LAUNDER, B. E.; SPALDING, D. B. Lectures in mathematical models of turbulence. p. 275–277, 1972.

LESIEUR, M. et al. Large-Eddy Simulations of Turbulence. Cambridge University Press, 2005. ISBN 9780521781244. Disponível em: https://books.google.com.br/books?id=FWmsrNv3BYoC.

LI, Q. et al. Numerical investigation on the coupled mechanisms of bubble breakup in a venturi-type bubble generator. Engineering Applications of Computational Fluid Mecha nics, Taylor & Francis, v. 16, n. 1, p. 229–247, 2022.

LIMA, P. S. et al. Identificação de padrões de escoamentos multifásicos em sistemas core annular flow baseados em fluidodinâmica computacional utilizando agrupamentos fuzzy. Universidade Federal da Bahia.

LOPES, L. B. F. Estudo do escoamento turbulento em um canal convergente-divergente. 2017.

LORENA, A. C.; CARVALHO, A. C. Introdução as máquinas de vetores suporte. RITA, v. 14, n. 2, p. 43–67, 2003.

MALISKA, C. R. Fundamentals of Computational Fluid Dynamics: The Finite Volume Method. [S.l.]: Springer Nature, 2023. v. 135. 10 e 196 p.

REZENDE, S. Sistemas inteligentes: fundamentos e aplicações. Manole, 2003. ISBN 9788520416839. Disponível em: .

ROSMAN, P. Modelos de circulação em corpos d'água rasos. Métodos Numéricos em Recursos Hıdricos. Coleçao da ABRH–Associaçao Brasileira de Recursos Hıdricos, v. 1, p. 156–221, 1989.

SHEN, C. et al. Using deep learning to recognize liquid–liquid flow patterns in micro channels. AIChE Journal, Wiley Online Library, v. 66, n. 8, p. e16260, 2020.

SUN, Y. et al. A comparative study of oil–water two-phase flow pattern prediction based on the ga-bp neural network and random forest algorithm. Processes, MDPI, v. 11, n. 11, p. 3155, 2023.



prh anp

anp | Gestão: FAPESP