Gestão: FAPESP

Reunião de Acompanhamento e Avaliação - RAA 2026

Abordagem Baseada em Explicabilidade Para a Avaliação de Modelos de Aprendizado de Máquina no Monitoramento da Integridade Estrutural de Poços de Petróleo.

prhanp 56/UFAL

Silva, A. C. A. [1]; Gouveia, L. P. [2]; Vieira, T. M. A.[3]

[1]Bolsista do PRH 56/UFAL, curso de Pós-graduação em Engenharia Civil, Maceió – AL. E-mail: andressa.silva@ctec.ufal.br

[2]Docente do curso de Engenharia de Petróleo na Universidade Federal de Alagoas, Maceió – AL. E-mail: lucas.gouveia@lccv.ufal.br

[3]Docente do curso de Ciência da Computação na Universidade Federal de Alagoas, Maceió – AL. E-mail: thalesv@gmail.com

MOTIVAÇÃO E FUNDAMENTAÇÃO

- Poços offshore exigem monitoramento contínuo e confiável por séries temporais multivariadas.
- Modelos de Machine Learning detectam anomalias, mas falsos positivos/negativos e baixa interpretabilidade dificultam a confiança.
- Estudo realizado pela Unidade de Operações de Exploração e Produção da Petrobras no Espírito Santo (UO-ES):



1.514.000 barris de petróleo foram perdidos devido a anomalias em 2016.



US$ 50 por barril.



US$ 75,7 milhões por ano

- A proposta integra segmentação, DTW e XAI para unir desempenho preditivo e interpretabilidade.

OBJETIVOS

- Desenvolver e validar uma abordagem integrada baseada em explicabilidade para apoiar a avaliação e seleção de modelos de ML no monitoramento da integridade de poços.
- Caracterizar conjunto de dados e comparar pipelines de preparação.
- Identificar assinaturas temporais por DTW e sensores representativos.
- Avaliar explicações quanto à fidelidade, estabilidade e coerência física.

APLICAÇÃO NO SETOR DE PETRÓLEO E ENERGIA

- Pesquisa desenvolvida em parceria com Projeto PDI ANP nº 23599-4 / Petrobras / Desenvolvimento de produtos digitais para projeto e gestão de integridade de estrutura de poço.

Tecnológicos
pipeline eficiente e interpretável para detecção de anomalias

Operacionais
diagnósticos mais confiáveis e apoio ao especialista

Financeiros
menor custo computacional e redução de perdas por diagnóstico tardio

METODOLOGIA PROPOSTA

1 Dados
3W Dataset + anomalias ICV

2 Pré-processamento
filtragem, interpolação, normalização

3 Segmentação
derivadas + U-Net + estratégia híbrida
*aplicado apenas aos dados de ICV

4 Avaliação
redução de dados + classificação
*aplicado apenas aos dados de ICV

5 Assinaturas DTW
recorrência, separação e normalidade

6 XAI
sensores relevantes + validação física

RESULTADOS PARCIAIS

Tabela 1 - Descrição do conjunto de dados

Classes	Descrição	Real	Simulado	Desenhado	TOTAL
0	Normal	594	-	-	594
1	Aumento abrupto de BSW	4	114	10	128
2	Fechamento espúrio da DHSV	22	16	-	38
3	Slugging severo	32	74	-	106
4	Instabilidade de fluxo	343	-	-	343
5	Perda rápida de produtividade	11	439	-	450
6	Restrição rápida no PCK	6	215	-	221
7	Incrustação no PCK	36	-	10	46
8	Formação de hidratos na linha de produção	14	81	-	95
9	Formação de hidratos na linha de serviço	57	150	-	207
10	Fechamento espúrio da ICV	10	-	-	10
	TOTAL	**1,129**	**1,089**	**20**	**2,238**

2.218 instâncias | **1.129** real | **1.089** simulada | **27 → 10** variáveis válidas

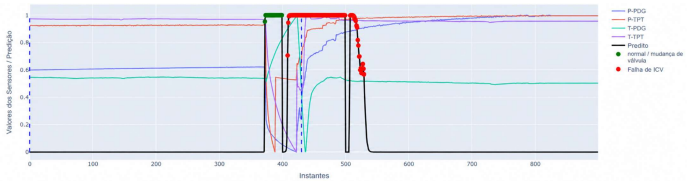
Cenário 1 | Segmentação de eventos relevantes + classificação

88% redução do volume de dados pouco informativos

0,65→0,99 ganho de F1-score com dados segmentados

10 casos de anomalia ICV avaliados

Figura 1 - Aplicação de segmentação de eventos importantes e classificação de anomalia de ICV



Fonte: Autores (2025)

Cenário 2 | Assinaturas temporais por DTW

- Identificar padrões temporais associados às diferentes anomalias e reconhecer quais sensores apresentam maior capacidade de caracterização de cada evento.

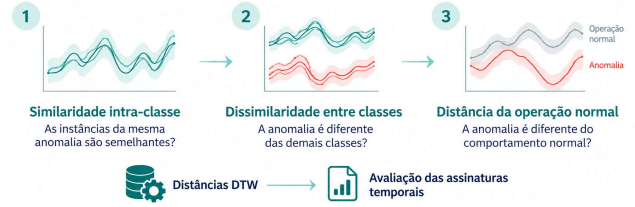
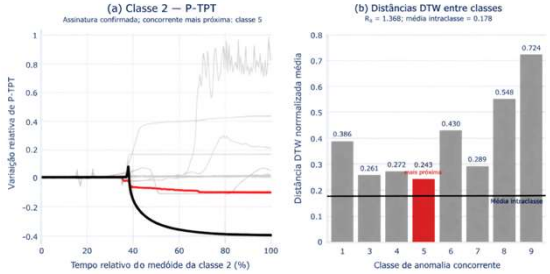


Figura 2 – Comparação entre distâncias DTW intraclasse e interclasse



Fonte: Autores (2026)

Tabela 2 - Assinatura final de cada classe anômala dos conjuntos de dados estudados

Classes	Anomalia	Assinatura Final	Tipo	Ra; cobertura	Classificação
1	Aumento abrupto de BSW	P-MON-CKP	Univariada	1.113; 8/9	Candidata
2	Fechamento espúrio da DHSV	P-TPT	Univariada	1.368; 8/9	Confirmada
3	Slugging severo	P-PDG + P-PTP	Multivariada	1.019; 8/9	Candidata
4	Instabilidade de fluxo	P-MON-CKP	Univariada	1.667; 8/9	Confirmada
5	Perda rápida de produtividade	T-MON-CKP + P-MON-CKP + T-JUS-CKP	Multivariada	1.116; 7/9	Candidata
6	Restrição rápida no PCK	P-PDG	Univariada	1.098; 8/9	Candidata
7	Incrustação no PCK	T-JUS-CKP	Univariada	1.526; 6/9	Confirmada
8	Formação de hidratos na linha de produção	T-TPT	Univariada	3.434; 8/9	Candidata
9	Formação de hidratos na linha de serviço	P-TPT	Univariada	1.235; 9/9	Candidata
10	Aumento abrupto de BSW	P-PDG	Univariada	1.431; 8/9	Confirmada

Fonte: Autores (2026)