



XLII Congresso Brasileiro de Sistemas Particulados

18 a 21 de Outubro de 2026

Vassouras, RJ

Inteligência Artificial Aplicada a Sistemas Particulados: Fundamentos e Perspectivas Tecnológicas

Prof. Dr. Luiz Augusto C. Meleiro
Dep^{to} de Engenharia Química – UFRRJ
Laboratório de Escoamento de Fluidos Giulio Massarani
meleiro@ufrrj.br

Tópicos da Apresentação

1. Introdução: Particularidades e Desafios de Engenharia dos Sistemas Particulados
2. Aspectos do Uso da IA na Pesquisa Científica
3. Fundamentos de Inteligência Artificial e Aprendizado de Máquina
4. Obtenção de Dados e Desenvolvimento e Validação de Modelos
5. Integração entre IA/ML e Modelos Fenomenológicos
6. Aplicações e Estudos de Caso
7. Perspectivas Tecnológicas e Mensagem Final

INTRODUÇÃO

1) *Particularidades e Desafios de Engenharia dos Sistemas Particulados*

Sistemas Particulados: Particularidades e Desafios de Engenharia

- **Escopo:** Populações de partículas sólidas, em contato entre si ou dispersas em um fluido, presentes em diferentes operações de engenharia.
- **Operações:** Peneiramento, moagem, mistura, sedimentação, fluidização, transporte de sólidos, etc.
- **Variáveis de interesse:** Distribuição de tamanhos, concentração de sólidos, vazão mássica, qualidade da separação, regime de escoamento, etc.
- **O que observar.** Queda de pressão, flutuações de pressão, vibração, imagens e distribuição dos sólidos.
- **Desafio:** Como relacionar as medições disponíveis, os mecanismos de interação e as condições operacionais às propriedades e ao comportamento do processo?

Particularidades e Desafios de Engenharia dos Sistemas Particulados

Propriedades das Partículas e Resposta do Conjunto

- **Polidispersidade:** Partículas diferem em tamanho, forma e densidade.
Um diâmetro médio pode ocultar distribuições com respostas distintas.
- **Efeitos de superfícies e umidade:** Rugosidade, atrito e forças coesivas alteram mobilidade, empacotamento e tendência à aglomeração.
- **População em evolução:** Quebra, agregação e crescimento podem modificar a distribuição de tamanhos ao longo do processo.
- **Consequência para a engenharia:** A resposta do conjunto depende da distribuição de propriedades e de sua evolução, além dos valores médios.

Particularidades e Desafios de Engenharia dos Sistemas Particulados

Complexidade Inerente: Interações e Mecanismos Coletivos

- **Partícula–partícula e partícula–parede:** Contatos, atrito e colisões dissipativas controlam a transmissão de forças e o movimento.
- **Coesão:** Forças de superfície e, em materiais parcialmente molhados, pontes líquidas podem favorecer aglomeração e dificultar o escoamento.
- **Partícula–fluido:** Arrasto, empuxo e propriedades do fluido acoplam o movimento das fases.
- **Resposta coletiva:** Segregação, formação de aglomerados, canais preferenciais e mudanças de regime dependem também da concentração, da geometria e das condições operacionais.

Particularidades e Desafios de Engenharia dos Sistemas Particulados

Medição e Representatividade dos Dados: UM DESAFIO CENTRAL

- **Observação parcial do sistema:** Imagens revelam projeções e regiões visíveis.
Opacidade e heterogeneidade espacial limitam a observação do interior e a representatividade das amostras.
Oclusão e amostragem podem limitar a representatividade.
- **Sensores indiretos:** Sinais de pressão, acústica ou vibração, além de imagens, precisam de calibração que considere outras variáveis do processo e as condições de aquisição.
- **Instrumentação adequada.** Posição dos sensores, taxa de aquisição, resposta dinâmica e ruído influenciam a informação disponível.
- **Referência experimental:** Calibração, incerteza e representatividade devem acompanhar a interpretação dos sinais e sua comparação com medições independentes.
Estimativas das propriedades exigem medições independentes e caracterização da incerteza.
- **Generalização:** Lotes, materiais e condições operacionais distintos devem entrar na avaliação do modelo, conforme o uso pretendido.

Particularidades e Desafios de Engenharia dos Sistemas Particulados

Modelagem Matemática: Descrição Física e Limitações

- **Modelos matemáticos:** Equações de conservação, métodos estatísticos, correlações empíricas, balanços populacionais, CFD e DEM podem ser adequados às perguntas de engenharia e permitem estimar respostas globais.
- **Escolha do modelo.** Precisão requerida e domínio de validade orientam a seleção. Contudo, a complexidade física, isoladamente, não demonstra vantagem do aprendizado de máquina.
- **Limitações e lacunas da abordagem fenomenológica:** Relações constitutivas, parâmetros de interação podem exigir informação adicional. Custo computacional elevado condicionam a escala, a precisão e a rapidez da previsão.
- **Abordagem integrada:** Utilizar as **equações de conservação** para preservar a estrutura mecanista e o **aprendizado de máquina** para estimar componentes pouco conhecidos. Essa combinação caracteriza uma forma de **“Modelagem Híbrida”**.

Particularidades e Desafios de Engenharia dos Sistemas Particulados

Oportunidades para a IA e ML

- **Caracterização e monitoramento:** Aprendizado de máquina pode relacionar imagens e/ou sinais às propriedades das partículas e às variáveis operacionais.
- **Modelagem:** Dados históricos de processo podem auxiliar a estimação de parâmetros, a construção de relações constitutivas e a aproximação de simuladores.
- **Critério de validade:** O desempenho depende da representatividade dos dados, da incerteza e das condições de teste.
- **Questão para a pesquisa científica:** Qual evidência sustenta a previsão e qual sustenta a explicação do mecanismo?

Contudo...

2) Aspectos do Uso da IA na Pesquisa Científica

Um Convite à Reflexão: A pesquisa impulsionada pela IA ameaça nossa verdadeira compreensão e cria uma ilusão de conhecimento?

- Lisa Messeri e Molly Crockett discutiram os benefícios e riscos do uso de IA na pesquisa científica.
- **Atratividade:** Promessas de melhorar a produtividade e a objetividade mediante a superação de limitações cognitivas humanas.
- **Alerta:** Ao explorar nossas limitações cognitivas, as soluções de IA nos torna vulneráveis a ilusões de compreensão nas quais **acreditamos compreender mais sobre o mundo do que efetivamente compreendemos**.
- **Risco:** A proliferação de ferramentas de IA na ciência traz o risco de introduzir uma fase da investigação científica em que **produzimos mais, mas compreendemos menos**.

Pacto faustiano???

Aspectos do Uso da IA na Pesquisa Científica

▪ Visões de IA para a Pesquisa Científica

- Os cientistas precisam lidar com diversas restrições à pesquisa, incluindo tempo finito, orçamentos fixos e capacidades cognitivas limitadas.
- As ferramentas de IA são vistas como soluções para essas barreiras, permitindo que os cientistas sejam mais produtivos, mais objetivos e livres de vieses e subjetividade.
- As autoras propuseram uma taxonomia com quatro visões distintas de IA:
 1. Oráculo,
 2. Substituto,
 3. Analista Quantitativo, e
 4. Árbitro.

Aspectos do Uso da IA na Pesquisa Científica

As autoras propuseram uma taxonomia com quatro visões distintas de IA:

Visão da IA para a Pesquisa	Promessa	Risco
Oráculo	Sintetizar a literatura e apoiar a formulação de hipóteses.	Confundir acesso à informação com compreensão científica: Ilusão de Conhecimento.
Substituto	Gerar dados sintéticos para complementar ou substituir a coleta de dados reais, dispendiosa e demorada.	Reproduzir vieses e restringir a investigação aos fenômenos representados pelo modelo.
Analista Quantitativo	Automatizar análises e identificar padrões ocultos em dados complexos.	Dificultar a interpretação dos resultados científicos e confundir capacidade preditiva com explicação dos fenômenos.
Árbitro	Agilizar a avaliação científica e estimar mais facilmente a replicabilidade dos resultados.	Presumir a imparcialidade da IA e conferir autoridade excessiva às suas avaliações sobre o mérito científico e a validade dos resultados.

Aspectos do Uso da IA na Pesquisa Científica

Síntese e Perspectivas

- Esses **benefícios potenciais** da IA merecem ser considerados seriamente, mas é fundamental também considerar uma possibilidade não desejada:
 - Essas ferramentas podem, de fato, limitar, em vez de ampliar, a compreensão científica.
- Em outras palavras, ao lado de seus **benefícios epistêmicos** potenciais, *Oráculos, Substitutos, Analistas Quantitativos e Árbitros* de IA apresentam **riscos epistêmicos** quando os cientistas confiam cegamente neles como parceiros na produção de conhecimento.
- Os cientistas precisam considerar não apenas as limitações técnicas e o potencial da IA, mas também como ela pode afetar as práticas sociais de produção de conhecimento científico.

Com discernimento, avancemos! A IA como apoio ao desenvolvimento científico.

Modelos baseados em IA: Por que, quando e como utilizá-los

POR QUÊ?	QUANDO?	COMO?
<ul style="list-style-type: none">• Analisar dados complexos.	<ul style="list-style-type: none">• Pergunta de engenharia definida: o que queremos determinar sobre o sistema e em quais condições.	<ul style="list-style-type: none">• Integrar dados e informação física.• Comparar alternativas e validá-las.• Avaliar incertezas, limites e a consistência das conclusões.
<ul style="list-style-type: none">• Identificar padrões ocultos em dados de processo.	<ul style="list-style-type: none">• Disponibilidade de dados representativos (qualidade e quantidade).	<ul style="list-style-type: none">• Comparar e validar em condições independentes.
<ul style="list-style-type: none">• Ampliar a capacidade de análise e previsão.	<ul style="list-style-type: none">• Benefício demonstrável frente a métodos de referência	<ul style="list-style-type: none">• Avaliar incertezas e limites.

Com discernimento, avancemos!

A IA como apoio ao desenvolvimento científico.

Fundamentos para o uso criterioso e oportunidades de integração com ML

- **O Aprendizado de Máquina pode complementar a modelagem fenomenológica em quatro tarefas:**
 1. **Estimar parâmetros de modelos físicos:** Identificar coeficientes e constantes a partir de dados experimentais.
 2. **Representar relações constitutivas pouco conhecidas:** Aprender relações a partir de dados para completar modelos físicos.
 3. **Interpretar medições indiretas:** Estimar concentração de sólidos ou vazão a partir de sinais e imagens.
 4. **Construir aproximações de menor custo computacional:** Aproximar respostas de CFD-DEM e de balanços populacionais com modelos substitutos.

Com discernimento, avancemos! A IA como apoio ao desenvolvimento científico.



- “O experimento é o único juiz da verdade científica”.
Richard Feynman. The Feynman Lectures on Physics, Vol. I.
- “Em Deus confiamos. Todos os demais devem apresentar dados.”
Atribuído a W. Edwards Deming (Estatístico, Professor, Autor e Consultor estadunidense).

3) Fundamentos de Inteligência Artificial e Aprendizado de Máquina

O NASCIMENTO DA INTELIGÊNCIA ARTIFICIAL: 1956 (70 anos em 2026!)

JOHN McCARTHY

- ✓ Considerado o pai da Inteligência Artificial. Ele próprio cunhou o termo.
- ✓ Também criou a linguagem de programação **LISP** (1958).
- ✓ Organizou a Conferência de Dartmouth (dois meses durante o verão de 1956, na Dartmouth College): *Marco Zero e o local oficial do nascimento da IA.*
- ✓ Reuniu pesquisadores do EUA interessados na Teoria dos Autômatos, Redes de Neurônios Artificiais e Estudo da Inteligência para discutir a seguinte conjectura:
- ✓ **Premissa:**
“Cada aspecto da aprendizagem ou qualquer outra característica da inteligência podem, em princípio, ser descrito de forma tão precisa que uma máquina pode ser construída para simular esses conceitos”.



Progressos fundamentais
não podem ser alcançados
através de avanços
incrementais em
tecnologias existentes.

PENSADOR John McCarthy

1956 Dartmouth Conference: The Founding Fathers of AI




John MacCarthy



Marvin Minsky



Claude Shannon



Ray Solomonoff



Alan Newell



Herbert Simon



Arthur Samuel



Oliver Selfridge



Nathaniel Rochester




Trenchard More


Fundamentos de Inteligência Artificial e Aprendizado de Máquina

PRINCIPAIS RAMOS E CAMPOS DA INTELIGÊNCIA ARTIFICIAL

Abordagens e campos inter-relacionados — uma organização didática



Principais Técnicas de Aprendizado de Máquina



Destaque:

✓ Inteligência Artificial:


- Tarefas de percepção, raciocínio, geração e apoio a decisões. Também inclui abordagens baseadas em regras (SE).

✓ Aprendizado de Máquina (*Machine Learning*):


- “Um subgrupo da IA cujos algoritmos dão aos computadores a habilidade de aprender sem serem explicitamente programados” (A. Samuel).
- São algoritmos que podem aprender com os seus erros e fazer previsões a partir de dados.
- Ajuste de modelos a partir de dados para uma tarefa definida.
- Representações: Características aprendidas a partir dos dados.
- ML compartilha métodos com a estatística, a identificação de sistemas e a otimização.

✓ Aprendizado Profundo (*Deep Learning*):


- É um subconjunto do ML.
- São Redes Neurais com MUITAS camadas (até centenas), que aprendem a partir de enormes quantidades de dados e com auxílio de processadores muito mais potentes (GPU).
- A composição de camadas que aprendem representações.



Principais Técnicas de Aprendizado de Máquina



Principais Técnicas de Aprendizado de Máquina



Adaptado de: LUI, H. Which machine learning algorithm should I use? SAS Institute, 2020.
Infográfico: ChatGPT



Como Selecionar um Algoritmo de Aprendizado de Máquina em Função da Tarefa

Identifique a tarefa e compare modelos candidatos por validação.

Sim

Há uma variável-alvo de referência?

Não


APRENDIZAGEM SUPERVISIONADA

Usa dados rotulados (com variável-alvo) para aprender a prever.

CLASSIFICAÇÃO

Prever uma categoria?


- Regressão logística • Naive Bayes
- Árvores de decisão
- Máquinas de vetores de suporte (SVM)
- Florestas aleatórias (Random Forest)
- Árvores com boosting de gradiente
- Redes neurais



REGRESSÃO

Prever um valor numérico?

- Regressão linear • Ridge • Lasso
- Árvores de regressão
- Regressão por vetores de suporte (SVR)
- Florestas aleatórias (Random Forest)
- Árvores com boosting de gradiente
- Redes neurais




APRENDIZAGEM NÃO SUPERVISIONADA

Encontra padrões nos dados sem usar variável-alvo.

AGRUPAMENTO

Descobrir grupos semelhantes?

- K-means: variáveis numéricas
- K-modes: variáveis categóricas
- DBSCAN: grupos por densidade
- Agrupamento hierárquico: estrutura em níveis
- Misturas gaussianas (GMM): grupos probabilísticos




REDUÇÃO DE DIMENSIONALIDADE

Obter uma representação mais compacta?

- PCA: análise de componentes principais
- SVD truncada: aproximação de baixa dimensão


Para representação de textos:

- LSA: análise semântica latente via SVD
 - LDA: alocação latente de Dirichlet
- Aqui, LDA é um modelo de tópicos.



A escolha final depende dos dados, da validação, da interpretabilidade e do custo computacional.


Marcos Importantes na História das Redes Neuronais Artificiais



Marcos Importantes na História das Redes Neurais Artificiais

Evolução das redes neurais


Marcos seleccionados de 1943 a 2023







Cronologia seletiva; espaçamento não proporcional ao tempo. Dados de preprints e publicações indicadas quando distintas.

Adaptação e ampliação da figura fornecida, com base nos trabalhos originais dos autores indicados.

Características dos Modelos de Aprendizado (ML e DL)




Características dos Modelos de Aprendizado (ML e DL)




Vantagens e Limitações de Cada Abordagem:

Por que o “Big Data” favoreceu a IA e, especificamente, o *Deep Learning*?




O que já podemos fazer com *Deep Learning*

Image recognition



Speech recognition



Características dos Modelos de Aprendizado (ML e DL)

Por que somente agora estamos usando essas técnicas?


Conjuntos de dados maiores



IMAGENET 10 milhões de imagens rotuladas

You Tube 8 milhões de vídeos categorizados

Hardware mais potente



Lei de Moore

Custo por GB em 1995: US\$ 1.000

Custo por GB em 2020: US\$ 0,02

Algoritmos mais inteligentes



Redes neurais recorrentes

Redes neurais convolucionais

LSTM

4) *Obtenção de Dados e Desenvolvimento e Validação de Modelos para ML*

Critérios para aplicações em engenharia



DADOS Informação relevante e confiável

Representatividade

- Diversidade de condições, materiais e regimes
- Ensaios independentes: quantidade não substitui diversidade
- Variáveis relevantes para a grandeza de interesse

Qualidade e rastreabilidade

- Calibração, unidades, ruído e incertezas
- Valores ausentes e qualidade dos rótulos
- Origem e condições de cada ensaio documentadas

Separação e preparo

- Treino, validação e teste conforme o uso previsto
- Respeitar ensaios, lotes e dependências temporais
- Ajustar o pré-processamento apenas no treino de cada partição



MODELOS Previsões adequadas à aplicação

Adequação e complexidade

- Método compatível com a tarefa e os dados
- Complexidade suficiente, com controle do sobreajuste
- Comparação com modelos de referência

Avaliação e generalização

- Desempenho em dados independentes
- Métricas adequadas: MAE/RMSE, precisão/F1, IoU/Dice
- Erros por condição e impacto na decisão


Confiabilidade e uso

- Coerência física e robustez ao ruído
- Custo computacional e interpretabilidade
- Incerteza e limites de validade explícitos

A qualidade dos dados e a validação do modelo sustentam a decisão de engenharia.

Tarefa de Aprendizagem (Supervisionada): Dados, Modelo e Ajuste

1 TREINAMENTO



2 USO OU INFERÊNCIA



PARÂMETROS

Valores ajustados no treinamento.

Exemplos: coeficientes, pesos e vieses.

HIPERPARÂMETROS

Configurações do modelo e do treinamento.

Exemplos: profundidade da árvore e taxa de aprendizagem.
Selecionados com apoio da validação.

Treinar é ajustar parâmetros. Generalizar é obter bom desempenho em novos dados do domínio de interesse.

Tarefa de Aprendizagem: Dados, Modelo e Ajuste


Seleção do Modelo Adequado ao Problema

Princípio da Parcimônia (Navalha de Ockham):

- “Entre modelos com desempenho de generalização comparável e que atendam aos requisitos da aplicação, deve-se preferir aquele que introduz menos complexidade desnecessária.”
ou, simplesmente...
- O melhor modelo é o modelo mais simples capaz de resolver o problema.

Relação linear e modelo muito complexo

A complexidade adicional precisa ser justificada pelo desempenho de validação.




Complexidade possivelmente desnecessária

Comparar com uma regressão linear antes de adotar um modelo mais complexo.

Relação não linear e modelo insuficiente

Uma reta não consegue representar a curvatura presente nos dados.




Capacidade de representação insuficiente

Selecionar uma estrutura capaz de descrever a relação não linear e validá-la.

Quantidade de Dados e a Complexidade do Modelo


Modelos mais flexíveis geralmente exigem mais informação para generalizar.



Dados suficientes: quantidade, diversidade, independência e qualidade

Não existe uma proporção universal entre número de registros e número de parâmetros.
Verifique a suficiência com curvas de aprendizagem e avaliação em dados independentes.

5) Integração entre Modelos Fenomenológicos e Aprendizado de Máquina



Representação de Modelagem Híbrida

- As equações de conservação estruturam o modelo fenomenológico, enquanto o ML estima parâmetros ou termos de fechamento a partir dos dados experimentais.
- O confronto entre previsões e medições permanece sob avaliação crítica dos pesquisadores.

6) Exemplos de Aplicações da IA na Indústria de Processos

Laboratório de Escoamento de Fluidos Giulio Massarani



Equipe de Pesquisadores do LEF-UFRRJ



Coordenadores



Cláudia Miriam Scheid
Coordenadora do LEF



Luís Américo Calçada
Coordenador do LEF



Cristiano Agenor de Araújo
Professor Colaborador






Filipe Arantes Furtado
Professor Colaborador



Luiz Augusto da Cruz Meleiro
Professor Colaborador

Principais Linhas de Pesquisa do LEF

- **Perfuração de Poços:** Fluidos de perfuração e suas interações com poço
- **Petrofísica:** Propriedades físicas das rochas e suas relações com os fluidos que ocupam os poros






Algumas Características dos Fluidos de Perfuração

- Sistemas multifásicos que podem apresentar elevado teor de sólidos, conforme a formulação, e a incorporação de cascalhos.
- Geralmente não newtonianos.
- Podem apresentar tensão limite de escoamento.
- Transportam e mantêm partículas sólidas em suspensão.
- Suas propriedades dependem da concentração e das características dos sólidos, da composição do fluido e das condições operacionais: **reologia, a densidade, a estabilidade elétrica e o teor iônico.**

Monitoramento em Tempo Real de Fluidos de Perfuração




OBJETIVO


- Desenvolver técnicas capazes de monitorar, em tempo real, as propriedades físico-químicas do fluido de perfuração durante e após a perfuração (reologia, densidade, estabilidade elétrica, teor iônico, cond. elétrica).

Monitoramento em Tempo Real de Fluidos de Perfuração


- **Variáveis Analisadas:** Condutividade, Densidade, Teor de Água e Viscosidade Aparente
- **Objetivo:** Monitoramento das “Estatísticas de Saúde do Processo” com PCA e LOF



Monitoramento de processo pelo acompanhamento de estatísticas de saúde.




Monitoramento de processo pelo acompanhamento da região de confiança.




Algoritmo de aplicação das técnicas de monitoramento de processos no diagnóstico de fluidos de perfuração.

Monitoramento em Tempo Real de Fluidos de Perfuração

- **Técnicas de ML Utilizadas: PCA e LOF (Aprendizado Não Supervisionado)**
 - PCA: Redução de dimensionalidade e extração de características, e
 - LOF: Detecção de anomalias ou observações atípicas.



Monitoramento das variáveis operacionais na planta piloto com estimação do estado do fluido pelo sistema diagnóstico.



Monitoramento das propriedades do fluido na planta piloto com estimação do estado do fluido pelo sistema diagnóstico com PCA e LOF.


O sistema diagnóstico foi capaz de identificar a perturbação realizada na composição do fluido de perfuração, com o número de **falsos positivos igual a 5%** e de **falsos negativos igual a 10%**.

Monitoramento em Tempo Real de Fluidos de Perfuração


- **Variáveis Analisadas:** Sinais acústicos e vibratórios do fluido de perfuração escoando em tubulações.
- **Objetivo:** Estimar, de forma não intrusiva, a concentração de sólidos no fluido de perfuração em escoamento, utilizando técnicas de aprendizado profundo (CNN).



METODOLOGIA




Fluxograma básico do tratamento de sinais.



Representação esquemática da arquitetura da CNN.





Microfone (PCB Piezotronics)



Acelerômetro (PCB Piezotronics).

Monitoramento em Tempo Real de Fluidos de Perfuração

- Técnicas de DL Utilizadas: Aprendizado supervisionado. Regressão com Rede Neural Convolutional (CNN).



Métricas por configuração da CNN.



Configuração	Pré-processamento	R² (médio)	RMSE	MAE
Vibração	FFT	0,9533	0,0532	0,0414
Acústica	FFT	0,9073	0,0764	0,0608
Acústica + Vibração	FFT	0,7812	0,1171	0,0970
Vibração	SEM FFT	0,9422	0,0586	0,0474
Acústica	SEM FFT	0,7246	0,1315	0,1100
Acústica + Vibração	SEM FFT	0,9507	0,0536	0,0429

Métricas por vazão na configuração:
Acústico + Vibracional sem FFT.

Vazões (m³/h)	R² (médio)	RMSE	MAE
1	0,9784	0,0356	0,0286
2	0,8982	0,0817	0,0558
3	0,9801	0,034	0,0299
4	0,9427	0,0555	0,0447
5	0,9541	0,0610	0,0555


Monitoramento em Tempo Real da Peneira Vibratória Durante a Perfuração

- **Objetivo:** Obter informações sobre a perfuração por meio da análise da operação da peneira vibratória.
- **Variáveis Analisadas:** Imagem (vídeo) da operação da peneira vibratória.



1) Análise de Cascalhos Secos: “Software de Apoio ao Geólogo”

- **Variáveis Analisadas:** Fotos dos cascalhos limpos.
- **Técnicas de DL Utilizadas:** Rede Convolutacional (CNN – Rede Convolutacional Profunda).



Cascalhos do mesmo poço separados por profundidade.



1) Análise de Cascalhos Secos: Software de Apoio ao Geólogo

- Variável Estimada:** Análise morfológica do cascalho.



True Class	Predicted Class					Accuracy	
	1180	150	2360	300	600		
1180	40					100.0%	
150		40				100.0%	
2360	3	1	36			90.0%	10.0%
300		4		36		90.0%	10.0%
600	4				36	90.0%	10.0%
						85.1%	88.9%
						100.0%	100.0%
						100.0%	100.0%
						14.9%	11.1%

True Class	Predicted Class										Accuracy	
	1	10	2	3	4	5	6	7	8	9		
1		8	1			1			1		100.0%	
10		11									100.0%	
2	3	2	4	1			1				36.4%	63.6%
3				8	1	1				1	72.7%	27.3%
4					7					4	63.6%	36.4%
5					2	9					81.8%	18.2%
6	3	2				2	3		1		27.3%	72.7%
7				1	1			9			81.8%	18.2%
8		1			1	5			1	3	9.1%	90.9%
9		5							1	5	45.5%	54.5%
											37.9%	80.0%
											80.0%	58.3%
											50.0%	75.0%
											100.0%	25.0%
											25.0%	38.5%
											75.0%	61.5%

Matriz Confusão da classificação do cascalho segundo: (E) Tamanho (Acurácia: 94,0%); (D) Categoria Acurácia: 61,7%.


2) Escoamento em Via Úmida com Peneira Piloto (Parceria UFU)

- **Variáveis Analisadas:** Vídeos da operação da peneira piloto.
- **Técnicas de DL Utilizadas:** Rede Convolucional (DL) e Visão Computacional.




2) Escoamento em Via Úmida com Peneira Piloto (Parceria UFU)

- **Variáveis Estimadas:** Área da peneira preenchida por sólidos e velocidade de escoamento da suspensão.



2) Escoamento em Via Úmida com Peneira Piloto (Parceria UFU)

- **Variáveis Estimadas:** Área da peneira preenchida por sólidos e velocidade de escoamento da suspensão.



3) Escoamento em Via Úmida com Peneira Real (Parceria UFU)

- **Variáveis Analisadas:** Vídeos da operação da peneira real.
- **Técnicas de DL Utilizadas:** Rede Convolutacional “YOLO” e “U-Net” (DL) e Visão Computacional.



Condições experimentais:

Peneira vibratória industrial operando a 1200 e 1800 RPM

Vazões de alimentação: 20, 30 e 40 m³/h


Suspensão: 98% líquido (água + 3% argila esmectita) e 2% sólidos (areia)

Gravações da região de praia (vista superior)

Local: FEQ/UFU – Grupo de Pesquisa em Processos de Energia e Separação


3) Escoamento em Via Úmida com Peneira Real (Parceria UFU)

- **Variáveis Estimadas:** Área preenchida por sólidos e velocidade de escoamento da suspensão (U-Net).



3) Escoamento em Via Úmida com Peneira Real (Parceria UFU)

- **Variáveis Estimadas:** Área da peneira preenchida por sólidos, velocidade de escoamento da suspensão e Morfologia dos aglomerados (Rede YOLO).



Relatório de Análise Morfológica

Análise do Vídeo (médias por frame)

Área (cm²) (média): 9.8205

Perímetro (cm) (média): 11.2803

Eixo Maior (cm) (média): 3.8054

Eixo Menor (cm) (média): 2.8173

Diâmetro Equivalente (cm) (média): 3.1667

Excentricidade (média): 0.5553

Nº médio de partículas por frame: 174.4452

4) Escoamento em Via Úmida com Peneira Real (LEF/UFRRJ)


- **Variáveis Analisadas:** Vídeos da operação da peneira real.
- **Técnicas de DL Utilizadas:** Rede Convolucional “YOLO+U-Net” (DL) e Visão Computacional.



Monitoramento em Tempo Real da Peneira Vibratória Durante a Perfuração

4) Escoamento em Via Úmida com Peneira Real (LEF/UFRRJ)

- Variáveis Estimadas:** Área da peneira preenchida por sólidos, velocidade de escoamento da suspensão e Morfologia (Rede U-Net).




Parâmetro	Valor Médio
Área (cm ²)	34,91
Perímetro (cm)	20,80
Eixo Maior (cm)	7,08
Eixo Menor (cm)	3,79
Diâmetro Equivalente (cm)	4,79
Excentricidade	0,747
Nº Partículas/Frame	15,76

Petrofísica

Monitoramento da Interface entre Fluidos em Separadores Visuais Durante Ensaios Petrofísicos

- **Variáveis Analisadas:** Deslocamento da interface água-óleo (menisco)
- **Técnicas de ML Utilizadas:** Deep Learning e Visão Computacional

Visão Computacional em Ensaios Petrofísicos Da Interface aos Volumes Produzidos



Monitoramento da Interface entre Fluidos em Separadores Visuais Durante Ensaios Petrofísicos

- **Leitura do Menisco em Ensaios Petrofísicos**
 - **Problema:** Os ensaios podem gerar **milhares de imagens** do separador, cuja **leitura manual** é repetitiva e depende do operador.
 - **Proposta:** Identificar **automaticamente** a interface entre os fluidos, fazer a leitura e converter sua posição em volume correspondente.
 - **Finalidade:** Acompanhar a produção de água e óleo e fornecer dados para a caracterização do escoamento em rochas.

Monitoramento da Interface entre Fluidos em Separadores Visuais Durante Ensaios Petrofísicos

- **Variáveis Analisadas:** Deslocamento da interface água-óleo (menisco).
- **Técnicas de ML Utilizadas:** Deep Learning e Visão Computacional (Automação e Controle).

Monitoramento da Interface entre Fluidos em Separadores Visuais Durante Ensaios Petrofísicos

➤ Visão Computacional e DL na Medição de Volumes

- **Rede convolucional:** Localiza o menisco e a régua fornece a referência.
- **Correção óptica e calibração:** Convertem posição na imagem em volume.


Monitoramento da Interface entre Fluidos em Separadores Visuais Durante Ensaios Petrofísicos

➤ Dados para a Caracterização Petrofísica

- **Saída do sistema:** Posição do menisco convertida em volumes ao longo do tempo, com correção óptica e calibração.
- **Validação apresentada:** Comparação com volumes bombeados (conhecidos).
- **Aplicação:** Integrar a produção medida à pressão, à injeção e a modelos físicos para apoiar a estimativa de saturações e permeabilidades relativas.

➤ Leitura Perfeita

1. O operador realiza uma leitura perfeita dentro da resolução da régua, que é de 1mm;
2. A incerteza na medida é de $\pm 0,05$ cm;
3. O operador corrige perfeitamente todos os efeitos de paralaxe e de lente, o que significa que suas leituras não são afetadas por aberrações de paralaxe ou de lente;
4. O erro máximo introduzido pelo operador nas leituras corresponde à medida de uma única leitura e do erro associado a bomba;
5. O aparato utilizado para a leitura perfeita também é perfeito, sem incertezas de construção.




(b) Experimento 09.

7) Perspectivas Tecnológicas

Cada oportunidade vem acompanhada de requisitos para sua aplicação.

Fusão de sensores



Combinar informações de imagens e sinais.

REQUISITO

Sincronização e calibração.

Aprendizado ativo




Selecionar experimentos mais informativos.

REQUISITO

Critério de seleção e avaliação da incerteza.

Transferência de aprendizado




Adaptar modelos a novos materiais ou equipamentos.

REQUISITO

Validação nas novas condições.

Gêmeos digitais




Atualizar a representação do processo com dados operacionais.

REQUISITO

Integração e atualização do modelo.

Otimização e controle



Apoiar decisões durante a operação.

REQUISITO

Confiabilidade, tempo de resposta e restrições operacionais.

Transformar potencial em resultados exige dados confiáveis, integração e validação.

Mensagem Final

IA e sistemas particulados: o futuro se constrói com vocês


Uma mensagem aos estudantes e jovens pesquisadores

Explore o potencial da IA



Caracterizar, prever, otimizar e controlar sistemas particulados.

Integre conhecimentos



Combine dados, modelos e fundamentos físicos.

Comece pela pergunta



Defina o problema antes de escolher o algoritmo.

Valide e questione



Examine resultados, incertezas e limites dos modelos.

Cultive uma postura científica



Curiosidade, autonomia e rigor científico.

Transforme conhecimento em soluções




Use a IA para ampliar sua capacidade de investigar e inovar.

Que a IA amplie nossa capacidade de investigar, e que o rigor científico dê significado às descobertas.

Agradecimentos às Instituições de Apoio e Fomento



Gratidão ao Time do LEF/UFRRJ!



MUITO OBRIGADO PELA ATENÇÃO!