



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

ANDRÉ CHRISTIANO CLARO MIGUEL

**DESENVOLVIMENTO DE UM SISTEMA DE VISÃO
COMPUTACIONAL PARA MONITORAMENTO EM
TEMPO REAL DE CASCALHOS DE PERFURAÇÃO
EM PENEIRAS VIBRATÓRIAS**

SEROPÉDICA
2026





ANDRÉ CHRISTIANO CLARO MIGUEL

DESENVOLVIMENTO DE UM SISTEMA DE VISÃO
COMPUTACIONAL PARA MONITORAMENTO EM
TEMPO REAL DE CASCALHOS DE PERFURAÇÃO EM
PENEIRAS VIBRATÓRIAS

Dissertação apresentada ao Programa de Pós Graduação em Engenharia Química da Universidade Federal Rural do Rio de Janeiro, como requisito parcial para a obtenção do grau de Mestre em Engenharia Química, Área de concentração: Tecnologia Química.

Orientador(a): Dr. Luiz Augusto da Cruz Meleiro

Coorientador(a): Dr. Luís Américo Calçada

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central/Central de Processamento Técnico

Ficha catalográfica elaborada
Com os dados fornecidos pelo(a) autor(a)

M634d Miguel, André Christiano Claro, 1995-
Desenvolvimento de um sistema de visão computacional
para monitoramento em tempo real de
cascalhos de perfuração em peneiras vibratórias / André
Christiano Claro Miguel. - Seropédica, 2026.
113 f.: il.

Orientador: Luiz Augusto da Cruz Meleiro.
Coorientador: Luís Américo Calçada.
Dissertação (Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-Graduação em
Engenharia Química, 2026.

1. visão computacional. 2. deep learning. 3.
processamento de imagens. 4. peneiras vibratórias. 5.
convolution neural network. I. Meleiro, Luiz Augusto
da Cruz, 1965-, orient. II. Calçada, Luís Américo, 1966
, coorient. III Universidade Federal Rural do Rio de
Janeiro. Programa de Pós-Graduação em Engenharia
Química. IV. Título.

É permitida a cópia parcial ou total desta Dissertação, desde que seja citada a fonte

**O presente trabalho foi realizado com apoio da Petrobras S.A. – Código de Financiamento
SAP 4600675541.**

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

ANDRÉ CHRISTIANO CLARO MIGUEL

**DESENVOLVIMENTO DE UM SISTEMA DE VISÃO
COMPUTACIONAL PARA MONITORAMENTO EM
TEMPO REAL DE CASCALHOS DE PERFURAÇÃO EM
PENEIRAS VIBRATÓRIAS**

Dissertação submetida como requisito parcial para
obtenção do grau de Mestre no Programa de Pós
Graduação em Engenharia Química, Área de
concentração em Tecnologia Química.

Dissertação aprovada em 04 de março de 2026.

BANCA EXAMINADORA:

Prof. Dr. Luiz Augusto da Cruz Meleiro - Orientador – DEQ/UFRRJ

Prof. Dr. Maurício Bezerra de Souza Jr. – Membro externo – DEQ/UFRRJ

Prof. Dr. Brunno Ferreira dos Santos – Membro externo – DEQM/PUC-RJ

AGRADECIMENTOS

Agradeço a Deus pela saúde e força ao longo desta longa jornada acadêmica e profissional.

A toda minha família, pelo incentivo, compreensão e apoio incondicional em todas as ocasiões, especialmente nos períodos em que precisava de vocês, sempre estiveram lá. Os momentos em que retorno para casa renovam minhas energias e me dão ânimo para seguir adiante.

A minha mãe Ângela e meu pai Andrés, que foram os responsáveis e fundamentais por eu estar chegando nesse momento tão especial, não medindo esforços para apoiar minhas conquistas e sempre valorizando os estudos.

A Universidade Federal Rural do Rio de Janeiro e ao PPGEQ/UFRRJ pela oportunidade de realização do mestrado e pelo suporte acadêmico ao longo do curso.

Ao meu orientador, Prof. Dr. Luiz Augusto da Cruz Meleiro, pela confiança, paciência, disponibilidade e valiosas contribuições técnicas e científicas que foram fundamentais para o desenvolvimento deste trabalho. Sua orientação e incentivo constante foram essenciais para a consolidação desta pesquisa.

A Universidade Federal de Uberlândia (UFU) e ao laboratório parceiro, pelo apoio na realização dos experimentos, disponibilização da infraestrutura e colaboração técnica indispensável para a obtenção dos dados experimentais utilizados neste trabalho.

Aos professores da UFRRJ, pelos conhecimentos compartilhados ao longo das disciplinas, que contribuíram significativamente para minha formação acadêmica e profissional.

Aos professores, amigos e técnicos do Laboratório de Escoamento Giulio Massarani (LEF/UFRRJ), por deixarem os dias mais leves com risadas, troca de experiências, apoio mútuo durante essa trajetória e muito trabalho de excelência sendo realizado.

Agradeço a Liliane, minha namorada que sempre esteve ao meu lado durante toda trajetória, pelo apoio, companheirismo e carinho foram fundamentais.

Aos meus amigos, pelo companheirismo, suporte e motivação ao longo desse percurso.

Agradeço à Petrobrás pelo apoio financeiro concedido para a realização deste trabalho, cuja contribuição foi fundamental para viabilizar as atividades de pesquisa.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. “This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001”.

*Dedico esta dissertação à memória do meu pai,
cujo amor e dedicação à família sempre foram farol e abrigo.
Seu exemplo vive em cada conquista que alcanço.*

RESUMO

MIGUEL, André Christiano Claro. **Desenvolvimento de um Sistema de Visão Computacional para Monitoramento em Tempo Real de Cascalhos de Perfuração em Peneiras Vibratórias**. 2026. 108 folhas. Dissertação (Mestrado em Engenharia Química) - Instituto de Tecnologia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2026.

Este trabalho apresenta o desenvolvimento e a validação de um sistema de visão computacional fundamentado em técnicas de Aprendizado Profundo (*Deep Learning*) para o monitoramento automatizado e em tempo real de cascalhos de perfuração em peneiras vibratórias, visando mitigar a subjetividade de análises humanas e a intermitência das inspeções visuais tradicionais na indústria de petróleo e gás. A metodologia integrou etapas experimentais e computacionais, utilizando peneiras vibratórias em escalas piloto e industrial operadas com suspensão sintética de cascalhos sob diferentes condições de rotação e vazão para a construção de um banco de dados de vídeos robusto, rotulado com auxílio da ferramenta Roboflow e do modelo SAM 2. Foram implementadas duas arquiteturas de redes neurais distintas: a U-Net, desenvolvida em Matlab e focada em segmentação semântica, e a YOLOv8, desenvolvida em Python e voltada para a detecção de objetos. Os resultados demonstraram a eficácia dos modelos treinados, com a U-Net alcançando acurácia de validação de aproximadamente 95% e *Intersection over Union* (IoU) de 85%, enquanto a YOLOv8 obteve um mAP@50 de 0,877 e uma precisão de aproximadamente 86%. O sistema desenvolvido permitiu a estimativa automática, contínua e não invasiva de parâmetros operacionais críticos, especificamente a porcentagem de área da tela preenchida por cascalhos e a velocidade média de escoamento da suspensão, apresentando concordância consistente com os dados experimentais de referência e capturando adequadamente as tendências físicas do processo, como o aumento da velocidade proporcional à vazão. Adicionalmente, foram implementadas interfaces gráficas para visualização em tempo real e extração preliminar de descritores morfológicos, consolidando a ferramenta como uma solução promissora para suporte à tomada de decisão operacional e otimização do controle de sólidos.

Palavras-chave: visão computacional; peneiras vibratórias; deep learning; detecção de objetos; monitoramento em tempo real.

ABSTRACT

MIGUEL, André Christiano Claro Miguel. **Development of a Computer Vision System for Real-Time Monitoring of Drilling Cuttings on Shale Shakers**. 2026. 108 pages. Dissertation (Master's in Chemical Engineering) – Institute of Technology, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2026.

This work presents the development and validation of a computer vision system based on Deep Learning techniques for the automated, real-time monitoring of drilling cuttings on shale shakers. The study aims to mitigate the subjectivity of human analysis and the intermittency of traditional visual inspections in the oil and gas industry. The methodology integrated experimental and computational stages, utilizing pilot and industrial-scale shale shakers operated with a synthetic cuttings suspension under various rotation and flow conditions to build a robust video database, labeled with the Roboflow tool and the SAM 2 model. Two distinct neural network architectures were implemented: U-Net, developed in Matlab and focused on semantic segmentation, and YOLOv8, developed in Python, oriented toward object detection. The results demonstrated the effectiveness of the trained models, with U-Net achieving approximately 95% validation accuracy and an Intersection over Union (IoU) of 85%, while YOLOv8 obtained an mAP@50 of 0.877 and a precision of approximately 86%. The developed system enabled the automated, continuous, and non-invasive estimation of critical operational parameters—specifically, the percentage of screen area covered by cuttings and the average flow velocity of the suspension. The system showed consistent agreement with experimental reference data and accurately captured the physical trends of the process, such as the proportional increase in velocity with flow rate. Additionally, graphical user interfaces (GUIs) were implemented for real-time visualization and preliminary extraction of morphological descriptors, establishing the tool as a promising solution for operational decision support and solids control optimization.

Keywords: computer vision; shale shakers; deep learning; object detection; real-time monitoring.

SUMÁRIO

CAPÍTULO 1. INTRODUÇÃO	13
1.1 Contextualização.....	14
1.2 Objetivos.....	15
1.2.1 Objetivos gerais	15
1.2.2 Objetivos específicos.....	16
1.3 Organização da dissertação.....	17
CAPÍTULO 2. REVISÃO BIBLIOGRÁFICA	18
2.1 Fluidos de perfuração.....	19
2.1.1 Propriedade dos Fluidos de perfuração.....	20
2.2 Unidade de controle de sólidos.....	24
2.2.1 Cascalhos produzidos durante a perfuração.....	26
2.2.2 Peneiras vibratórias.....	29
2.2.3 <i>Mud Logging</i>	37
2.2.4 Análise e monitoramento de cascalhos.....	39
2.3 Visão computacional aplicada a análise de cascalhos	41
2.3.1 Análise e segmentação de imagens.....	43
2.4 Redes neurais artificiais	45
2.4.1 Fundamentação Matemática	47
2.4.2 Aplicações na Indústria.....	48
2.4.3 Redes neurais convolucionais e arquiteturas modernas.....	50
2.5 Estado da arte de trabalhos na área de visão computacional	56
CAPÍTULO 3. METODOLOGIA.....	63
3.1 Visão geral da metodologia.....	64
3.2 Metodologia Experimental.....	65
3.2.1 Local dos experimentos e equipamentos utilizados.....	65
3.2.2 Composição da suspensão	66

3.2.3	Condições operacionais	67
3.2.4	Aquisição de vídeos e imagens do experimento.....	67
3.3	Metodologia computacional.....	67
3.3.1	Construção do banco de dados e rotulagem das imagens	69
3.3.2	Treinamento da rede U-Net e avaliação do efeito de hiperparâmetros.....	72
3.3.3	Treinamento da rede YOLOv8	73
3.3.4	Equacionamento dos parâmetros operacionais	74
3.3.5	Configuração do ambiente computacional e custo de treinamento e de seleção de hiperparâmetros da U-Net.....	76
3.3.6	Configuração do ambiente computacional e custo de treinamento da YOLOv8	78
3.3.7	Configuração de treinamento da rede YOLOv8 (Ultralytics)	78
CAPÍTULO 4. RESULTADOS E DISCUSSÃO		80
4.1	Resultados dos treinamentos dos modelos de redes neurais profundas	81
4.1.1	Desempenho do treinamento da U-Net (MATLAB)	81
4.1.2	Desempenho do treinamento da YOLOv8 (Python).....	85
4.2	Comparação entre os parâmetros estimados (Área Preenchida e Velocidade de Escoamento) pelos modelos e as referências experimentais.....	90
4.2.1	Área preenchida e Velocidade Média estimadas pelo software utilizando U-Net em Matlab.....	90
4.2.2	Área preenchida e Velocidade Média estimadas pelo software desenvolvido com YOLOv8 no ambiente Python.....	94
CAPÍTULO 5. CONCLUSÕES FINAIS		100
CAPÍTULO 6. SUGESTÕES PARA TRABALHOS FUTUROS		102
CAPÍTULO 7. REFERÊNCIAS BIBLIOGRÁFICAS		104
ANEXO 1. DECLARAÇÃO DE USO CONSCIENTE DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL		113

LISTA DE FIGURAS

Figura 2.1 - Representação ilustrativa do sistema de controle de sólidos.	24
Figura 2.2 – Ilustração de uma peneira vibratória industrial linear horizontal.....	29
Figura 2.3 - Mapeamento das regiões do processo de peneiramento vibratório.	32
Figura 2.4 – Contexto da evolução das redes neurais.....	45
Figura 2.5 - Arquitetura da rede U-Net.	54
Figura 2.6 - Arquitetura geral do modelo YOLOv8, dividida em Backbone, Neck e Head. ...	55
Figura 3.1 - Fluxograma do Software de Visão Computacional.	64
Figura 3.2 - Peneira Vibratória M-I SWACO da FEQ/UFU.	65
Figura 3.3 - Esquema da unidade experimental com indicação de seus principais componentes	66
Figura 3.4 - Exemplo de uma segmentação no Roboflow (polígonos amarelos - suspensão) do experimento realizado na UFU em 1200 RPM e 20 m ³ /h.	70
Figura 4.1. Imagem original da suspensão na peneira (a) e sua respectiva máscara binária (b) em uma velocidade de 1200 RPM e 20m ³ /h de vazão.	81
Figura 4.2. Curva de treinamento da rede U-Net.	83
Figura 4.3. Resultado da segmentação da suspensão na peneira: (a) imagem original adquirida durante o experimento; (b) máscara de segmentação gerada pela U-Net, evidenciando as regiões classificadas como suspensão.....	83
Figura 4.4. Matriz de confusão normalizada para as classes Areia e Background.....	84
Figura 4.5. Histograma do IoU médio obtido para o conjunto de validação da U-Net.....	85
Figura 4.6. Gráficos de evolução das perdas de treinamento e validação (box, classificação e DF) e métricas de desempenho (Precisão, Recall, mAP50) ao longo de 15 épocas de treinamento.	86
Figura 4.7 - Curva Precisão-Revocação (Precision-Recall) para o objeto de interesse, evidenciando a área sob a curva mAP@0.5.	87
Figura 4.8 - Matriz de confusão normalizada do treinamento YOLOv8.....	88
Figura 4.9- Detecção através de bounding boxes (caixas azuis) do modelo YOLOv8 durante o treino do modelo.....	89
Figura 4.10 - Interface de software de visão computacional em Matlab exibindo análise de vídeo em tempo real para operação em 1200RPM e 20 m ³ /h.	92
Figura 4.11 - Interface de software de visão computacional em Matlab exibindo análise de vídeo em tempo real para operação em 1800RPM e 40 m ³ /h.	93

Figura 4.12 - Interface de software de visão computacional em Matlab incluindo a análise de morfologia do vídeo em tempo real para operação em 1200RPM e 20 m ³ /h.....	94
Figura 4.13 - Interface de software de visão computacional em Python exibindo análise de vídeo em tempo real para operação em 1200RPM e 20 m ³ /h.	97
Figura 4.14 - Interface de software de visão computacional em Python exibindo análise de vídeo em tempo real para operação em 1800RPM e 40 m ³ /h.	98
Figura 4.15 - Interface gráfica de exibição ao operador do relatório de morfologia em uma operação de 1800RPM e 40 m ³ /h.	99

CAPÍTULO 1. INTRODUÇÃO

Resumo

O presente capítulo aborda o problema central do monitoramento de sistemas de controle de sólidos na indústria de petróleo e gás, destacando a importância crítica das peneiras vibratórias na manutenção das propriedades dos fluidos de perfuração e na eficiência operacional. Contextualiza-se a transição da indústria para os conceitos de *Digital Oilfield*, apontando as limitações dos métodos tradicionais de monitoramento, que dependem majoritariamente da inspeção visual humana e são sujeitos à subjetividade e intermitência. Diante desse cenário, justifica-se a necessidade de soluções tecnológicas baseadas em Visão Computacional e Aprendizado Profundo (*Deep Learning*) para automatizar a análise de cascalhos. São delineados o objetivo geral do trabalho, que consiste no desenvolvimento e validação de um sistema computacional capaz de estimar a porcentagem de área da tela preenchida por cascalhos e a velocidade de escoamento da suspensão, e os objetivos específicos, que incluem a realização de ensaios experimentais em escala piloto, a construção de um banco de dados robusto com auxílio de ferramentas de rotulagem assistida e analisar o desempenho de duas arquiteturas de redes neurais distintas: a U-Net, focada em segmentação semântica, e a YOLOv8, voltada para detecção de objetos. Por fim, apresenta-se a estrutura organizacional da dissertação, detalhando a distribuição do conteúdo ao longo dos seis capítulos que compõem o documento.

Palavras-chave: visão computacional; controle de sólidos; automação industrial; *deep learning*.

1.1 Contextualização

A perfuração de poços de petróleo e gás envolve a circulação contínua de fluidos de perfuração (lama de perfuração), cuja função principal é resfriar e lubrificar a broca, estabilizar as paredes do poço e transportar os cascalhos gerados durante a perfuração até a superfície. À medida que o fluido retorna à superfície, torna-se essencial a separação eficiente dos sólidos perfurados, tanto para evitar danos aos equipamentos quanto para manter as propriedades reológicas e operacionais da lama dentro dos parâmetros desejados. Nesse contexto, o sistema de controle de sólidos desempenha um papel fundamental no desempenho global do processo de perfuração (ASME, 2005).

O primeiro e mais importante equipamento desse sistema é a peneira vibratória (*shale shaker*), responsável pela separação primária dos cascalhos por meio de telas vibratórias inclinadas. O desempenho desse equipamento afeta diretamente a eficiência da separação sólido-líquido, a taxa de recuperação do fluido de perfuração e a estabilidade operacional do sistema como um todo. Entretanto, o monitoramento do comportamento da suspensão sobre a tela da peneira ainda é majoritariamente baseado em inspeção visual do operador na cabine *mud-logging* ou em sensores pontuais, que fornecem informações limitadas sobre a dinâmica real do escoamento superficial. Esse procedimento consiste em identificar e descrever os cascalhos a partir de suas propriedades físicas, como dimensões, geometria, aspecto superficial, tonalidade, entre outros fatores. Entretanto, por ser executada essencialmente por inspeção visual humana, essa prática tende a ser demorada e sujeita a erros, uma vez que os resultados dependem do julgamento e da experiência individual do operador. (FAGUNDES, 2018; ASME, 2005).

A quantidade de material sobre a tela, frequentemente representada pela área da tela preenchida por cascalhos (AP), e a velocidade média de escoamento dos sólidos da suspensão são parâmetros-chave para avaliar o regime de operação da peneira. Valores muito elevados de AP podem indicar sobrecarga do equipamento, desmoronamento de poço, redução da eficiência de separação e risco de transbordamento, enquanto valores muito baixos podem sugerir subutilização da tela. Da mesma forma, variações na velocidade do escoamento estão relacionadas a mudanças na condição operacional, como alterações de vazão, inclinação da peneira ou características reológicas da suspensão (ELLIS e SINGER, 2007).

Além disso, variações abruptas nas características dos cascalhos podem indicar eventos operacionais relevantes, como desgaste excessivo da broca, mudanças no mecanismo de ruptura da rocha ou instabilidades na parede do poço (ELLIS e SINGER, 2007). Dessa forma, o

monitoramento contínuo e quantitativo desses parâmetros é de grande interesse para a indústria de petróleo, tanto do ponto de vista operacional quanto econômico.

Embora o monitoramento de cascalhos de perfuração seja uma prática consolidada na indústria de óleo e gás para a manutenção da integridade do poço e otimização da taxa de penetração, a transição de métodos manuais e intermitentes para sistemas automatizados de alta fidelidade ainda enfrentam algumas barreiras. A análise do estado da arte revela que as soluções existentes, baseadas em processamento digital de imagem tradicional, apresentam desafios quando expostas às condições dinâmicas do ambiente de peneiramento, como variações drásticas de iluminação, vibrações mecânicas intensas e a opacidade dos fluidos de perfuração.

Nos últimos anos, técnicas de visão computacional e aprendizado de máquina têm sido cada vez mais exploradas para monitoramento e análise de processos industriais. Em particular, o uso de redes neurais profundas para segmentação e detecção em imagens tem demonstrado grande potencial para extração automática de informações relevantes em tempo real, sem interferência direta no processo (BADIS *et al.*, 2021). No contexto de peneiras vibratórias, a aplicação dessas técnicas permite a análise contínua do escoamento superficial da suspensão a partir de vídeos adquiridos por câmeras instaladas próximas ao equipamento.

Nesse cenário, a combinação de experimentação em escala piloto com métodos avançados de visão computacional representa uma abordagem promissora para superar as limitações dos métodos tradicionais de monitoramento. Ao permitir a estimativa automática da área da tela preenchida por cascalhos (AP), da velocidade média de escoamento dos sólidos e de características morfológicas da suspensão, essas técnicas podem fornecer suporte adicional à tomada de decisão operacional, contribuindo para maior eficiência e confiabilidade do processo de separação sólido-líquido.

É nesse contexto que se insere o presente trabalho, que propõe o desenvolvimento de um sistema de visão computacional para monitoramento de cascalhos de perfuração em peneiras vibratórias, integrando métodos de segmentação baseados em aprendizado profundo (U-Net e YOLOv8), cálculo de parâmetros operacionais e visualização em tempo real por meio de softwares dedicados de monitoramento.

1.2 Objetivos

1.2.1 Objetivos gerais

O objetivo principal deste trabalho consiste no desenvolvimento e validação de um sistema de visão computacional fundamentado em Redes Neurais Profundas (*Deep Learning*)

para o monitoramento automatizado de cascalhos de perfuração em peneiras vibratórias. O sistema visa estimar parâmetros operacionais críticos, especificamente a área da tela preenchida por cascalhos (AP), e a velocidade média de escoamento dos sólidos da suspensão, utilizando arquiteturas de redes neurais distintas (U-Net e YOLOv8), desenvolvidos em Matlab e Python, respectivamente, e validá-los com dados experimentais.

1.2.2 Objetivos específicos

Para alcançar o objetivo geral proposto, foram definidos os seguintes objetivos específicos:

- Realizar ensaios experimentais em escala piloto utilizando uma peneira vibratória industrial (M-ISWACO) e uma suspensão sintética de fluido de perfuração, variando as condições de rotação (1200 e 1800 RPM) e vazão (20, 30 e 40 m³/h) para a aquisição de uma base de dados de vídeos representativa.
- Construir um banco de dados robusto, empregando técnicas de rotulagem assistida pela ferramenta Roboflow e pelo modelo *Segment Anything Model 2* (SAM 2) para a geração de máscaras binárias precisas (*ground truth*).
- Aplicar técnicas de aumento de dados (*data augmentation*) para expandir a variabilidade do conjunto amostral e mitigar o sobreajuste (*overfitting*) durante o treinamento das redes.
- Treinar, validar e implementar duas arquiteturas de redes neurais: a rede U-Net (implementada em MATLAB) focada em segmentação semântica, e o modelo YOLOv8 (implementado em Python) focado na detecção de objetos através de *bounding boxes*.
- Desenvolver algoritmos para o cálculo automatizado da área da tela preenchida por cascalhos (AP), e a velocidade média de escoamento dos sólidos da suspensão, utilizando o rastreamento de deslocamento de centroides e a quantificação de pixels segmentados.
- Implementar interfaces gráficas de apoio ao operador em ambos os ambientes (MATLAB e Python) que permitam visualizar as detecções dos sólidos presentes na peneira e os gráficos de desempenho em tempo real.
- Implementar, de forma preliminar, a extração de descritores morfológicos dos sólidos para caracterização física dos cascalhos.

1.3 Organização da dissertação

Esta dissertação de mestrado está estruturada em sete capítulos, e sua organização textual apresenta-se da seguinte forma: O primeiro capítulo introduz o tema, apresentando uma breve contextualização e delineando os objetivos gerais e específicos desta pesquisa. No capítulo dois, é desenvolvida a revisão bibliográfica, que discute os conceitos fundamentais dos fluidos de perfuração, análise de cascalho, visão computacional e por fim o atual estado da arte sobre a temática do monitoramento de peneiras vibratórias. O terceiro capítulo descreve os materiais, as técnicas e metodologias empregadas, além do estudo concebido para avaliar a complexidade e eficiência dos algoritmos propostos. O quarto capítulo aborda os resultados obtidos e as respectivas discussões. O quinto capítulo, por sua vez, apresenta a conclusão do estudo. O capítulo seis contém as sugestões para trabalhos futuros e, por último, o capítulo 7 compila todas as referências bibliográficas utilizadas.

CAPÍTULO 2. REVISÃO BIBLIOGRÁFICA

Resumo

Este capítulo apresenta os conceitos básicos dos fluidos de perfuração e do sistema de circulação de fluidos, com ênfase nos sistemas de controle de sólidos e na análise de cascalhos em peneiras vibratórias durante a perfuração de poços de petróleo. Em seguida, são expostos os princípios da visão computacional e processamento de imagem e redes neurais, aspectos fundamentais para a compreensão inicial da proposta deste trabalho. Por fim, é apresentado o estado da arte, contemplando os principais estudos de caráter teórico, experimental e computacional que empregaram técnicas de visão computacional no monitoramento de peneiras vibratórias.

Palavras-chave: fluidos de perfuração; peneiras vibratórias; redes neurais convolucionais; estado da arte; monitoramento de processos

2.1 Fluidos de perfuração

Os fluidos de perfuração, também conhecidos como lamas de perfuração, consistem em sistemas formulados a partir de um fluido base associado a diferentes aditivos químicos, desenvolvidos com o objetivo de viabilizar e otimizar o processo de perfuração de poços de petróleo e gás (FANCHI, 2010). No contexto das operações petrolíferas, o uso adequado desses fluidos é considerado indispensável para garantir a segurança operacional, a integridade do poço e a eficiência da perfuração, sendo um dos principais fatores associados ao sucesso da atividade (GUIMARÃES *et al.*, 2007).

Diversos autores descrevem que os fluidos de perfuração desempenham simultaneamente múltiplas funções ao longo do processo, as quais podem variar em importância conforme as condições operacionais e geológicas encontradas. Entre suas funções primárias destacam-se o transporte eficiente do cascalho gerado pela broca até a superfície, permitindo sua posterior separação, bem como o resfriamento, a limpeza e a lubrificação da broca durante a perfuração (DARLEY e GRAY, 1988; GUIMARÃES E ROSSI, 2007; MITCHELL e MISKA, 2011). Além disso, esses fluidos atuam na redução do atrito entre a coluna de perfuração e as formações rochosas, contribuindo para a diminuição do desgaste mecânico dos equipamentos.

Outro papel fundamental do fluido de perfuração é o controle das pressões no interior do poço, por meio da aplicação de um gradiente hidrostático adequado, garantindo a estabilidade das paredes do poço e prevenindo influxos indesejáveis de fluidos das formações, como água, gás ou petróleo (CAENN e CHILLINGAR, 1996; THOMAS, 2001). A formação de uma película de baixa permeabilidade ao longo das paredes do poço também é essencial para minimizar perdas de fluido e preservar a integridade do reservatório.

Para que essas funções sejam desempenhadas de forma eficaz, o fluido de perfuração deve apresentar um conjunto de propriedades físico-químicas específicas. Entre as principais características desejáveis, destaca-se a estabilidade química ao longo de todo o processo de perfuração, de modo que suas propriedades não sejam significativamente alteradas por tratamentos operacionais ou por interações com as formações geológicas atravessadas (THOMAS, 2001). A capacidade de manter sólidos em suspensão, mesmo em situações de interrupção da circulação, é igualmente relevante, evitando a sedimentação do cascalho e possíveis obstruções no poço.

A estabilidade das paredes do poço constitui um dos aspectos mais críticos do processo, uma vez que falhas nesse controle podem resultar em desmoronamentos, comprometendo a

continuidade da perfuração, aumentando custos operacionais e elevando os riscos de acidentes (AADNØY e LOOYEH, 2011). Além disso, o fluido deve possibilitar a separação eficiente do cascalho na superfície, permitindo seu condicionamento e reutilização no sistema de circulação (CALÇADA *et al.*, 2015).

Do ponto de vista operacional, é igualmente desejável que o fluido não provoque corrosão ou danos aos equipamentos, assegurando maior vida útil dos componentes da coluna de perfuração. Paralelamente, o fluido deve permitir a adequada avaliação geológica das formações perfuradas, uma vez que as informações obtidas a partir dos cascalhos são essenciais para a tomada de decisões técnicas durante a perfuração (MITCHELL e MISKA, 2011).

Além dos aspectos técnicos e operacionais, a minimização dos impactos ambientais tem assumido papel cada vez mais relevante no desenvolvimento e na seleção de fluidos de perfuração. O descarte do cascalho gerado durante a perfuração pode carregar contaminantes oriundos do fluido, representando riscos ao meio ambiente, o que reforça a necessidade de formulações que conciliem desempenho técnico e sustentabilidade ambiental (CHARLES e SAYLE, 2010).

2.1.1 Propriedade dos Fluidos de perfuração

O desempenho de um fluido de perfuração está diretamente associado às suas propriedades físico-químicas, as quais devem ser cuidadosamente controladas ao longo de toda a operação de perfuração. Essas propriedades determinam a eficiência no transporte de cascalhos, a estabilidade do poço, o controle de pressão, a proteção dos equipamentos e a interação do fluido com as formações geológicas. Alterações inadequadas em qualquer uma dessas características pode resultar em problemas operacionais, aumento de custos e riscos à segurança (DARLEY e GRAY, 1988; CAENN e CHILLINGAR, 1996).

Entre as principais propriedades dos fluidos de perfuração destacam-se a densidade, o comportamento reológico, o teor de sólidos, o pH e a salinidade, as quais são interdependentes e frequentemente ajustadas por meio da adição de agentes químicos específicos, conforme as condições operacionais e geológicas encontradas na região explorada.

2.1.1.1 Densidade

A densidade do fluido de perfuração é uma das propriedades mais críticas, pois está diretamente relacionada ao controle de pressão no interior do poço. Essa propriedade determina o gradiente hidrostático exercido sobre as formações geológicas, sendo fundamental para

prevenir influxos indesejáveis de fluidos, como água, gás ou petróleo, bem como para evitar fenômenos como desmoronamentos, fraturas indesejadas, *kicks* e *blowouts* (THOMAS, 2001; CAENN e CHILLINGAR, 1996).

Valores inadequados de densidade podem ocasionar sérios problemas operacionais. Densidades inferiores às necessárias podem resultar em influxos de formação, enquanto densidades excessivamente elevadas podem provocar fraturas na formação, perdas de circulação e danos ao reservatório. A densidade do fluido é geralmente ajustada pela adição do fluido base utilizado a para diluição ou para a correção a adição de agentes adensantes, como barita ou hematita, devendo ser continuamente monitorada ao longo da perfuração (DARLEY e GRAY, 1988; MITCHELL e MISKA, 2011).

2.1.1.2 Reologia

O comportamento reológico dos fluidos de perfuração descreve a relação entre tensão de cisalhamento e taxa de deformação, sendo determinante para o escoamento do fluido tanto em regime laminar quanto turbulento. Propriedades como viscosidade aparente, viscosidade plástica, limite de escoamento e força gel são fundamentais para garantir o transporte eficiente do cascalho, a suspensão de sólidos em condições estáticas e a redução do desgaste mecânico dos equipamentos (THOMAS, 2001; MITCHELL e MISKA, 2011).

Este comportamento é tipicamente não-newtoniano, sendo projetado para exibir tixotropia. Como ressalta Noronha (2016), os fluidos de perfuração são formulados para gelificar gradativamente quando o cisalhamento cessa. Este fenômeno é essencial para impedir que os cascalhos oriundos da perfuração sedimentem durante as paradas, evitando assim graves problemas operacionais como o aprisionamento da coluna de perfuração e o colapso do poço (MACHADO, 2002).

Dessa forma, a reologia adequada permite que o fluido apresente baixa viscosidade durante a circulação, minimizando perdas de carga, e exatamente o comportamento gelificante descrito quando o escoamento é interrompido, garantindo a suspensão dos sólidos. O controle reológico e tixotrópico é geralmente obtido por meio da adição de polímeros, argilas e outros modificadores de fluxo, cuja seleção depende do tipo de fluido base e das condições do poço (DARLEY e GRAY, 1988; THOMAS, 2001).

2.1.1.3 Teor de sólidos

O teor de sólidos presentes no fluido de perfuração aumenta progressivamente durante a operação, principalmente devido à incorporação contínua de partículas geradas pelo corte das rochas pela broca (CHARLES e SAYLE, 2010). Esse acúmulo, se não for devidamente controlado, altera significativamente as propriedades como a densidade e a reologia do fluido, comprometendo a eficiência e a segurança de todo o processo de perfuração.

Para mitigar esse problema e manter as características do fluido dentro das faixas operacionais ideais, adotam-se o tratamento preventivo e tratamento corretivo. O tratamento preventivo consiste em estratégias que visam minimizar a incorporação e a dispersão fina dos sólidos no fluido. Isso pode ser alcançado por meio da inibição química, utilizando aditivos que aglomeram as partículas de rocha (como polímeros floculantes) e previnem sua dispersão em tamanhos coloidais, ou por meio do condicionamento físico, que busca manter as partículas em tamanhos maiores e mais facilmente removíveis (THOMAS, 2001; ASME, 2005);

Quando o teor de sólidos já excede os limites desejáveis, aplica-se o tratamento corretivo. Este envolve a remoção física dos sólidos indesejáveis por uma série de equipamentos, geralmente dispostos em estágios de acordo com o tamanho das partículas. O processo inicia-se nas peneiras vibratórias (*shakers*), responsáveis pela remoção dos sólidos grosseiros (cascalho). Em seguida, hidrociclones removem partículas de areia e silte. Para partículas ainda mais finas (coloidais), pode-se empregar centrífugas. Em casos específicos, recorre-se também à diluição com fluido novo ou ao uso de tanques de decantação para sedimentação gravitacional (THOMAS, 2001; ASME, 2005; MITCHELL e MISKA, 2011).

2.1.1.4 pH

O pH dos fluidos de perfuração é um parâmetro fundamental que regula o equilíbrio químico do sistema, influenciando diretamente a estabilidade dos aditivos, o comportamento reológico, os processos de corrosão nos equipamentos e a interação do fluido com as formações rochosas (DARLEY e GRAY, 1988; THOMAS, 2001).

A manutenção do pH em uma faixa adequada é crucial para a integridade da operação. Durante a perfuração, o fluido está sujeito a interações sólido-fluido com o cascalho e líquido-líquido com os fluidos de formação (como água ou contaminantes ácidos), que podem aumentar sua acidez. Para minimizar a corrosão dos equipamentos e da linha de circulação, o pH deve ser controlado e mantido em uma faixa tipicamente alcalina (FERRAZ, 2014; DARLEY e GRAY, 1988).

Valores de pH fora desta faixa podem desencadear problemas operacionais significativos. Em meios excessivamente ácidos (pH baixo), observa-se uma alteração nos parâmetros reológicos, com aumento significativo da viscosidade aparente e da tensão de escoamento, prejudicando a eficiência do escoamento (KHANDAL e TRADOS, 1988). Além disso, a acidez acelera os processos corrosivos nos equipamentos metálicos. Por outro lado, um pH excessivamente alcalinos podem degradar os polímeros e aditivos, além de promover a dispersão indesejada de argilas nas formações, afetando a estabilidade do poço (THOMAS, 2001; CAENN e CHILLINGAR, 1996).

2.1.1.5 Salinidade

A salinidade do fluido de perfuração corresponde à concentração de sais dissolvidos no sistema e constitui uma propriedade dinâmica, frequentemente modificada ao longo da perfuração em função da interação entre o fluido e as formações geológicas atravessadas. Além da adição intencional de sais durante a formulação do fluido, a salinidade pode ser significativamente alterada pela solubilização de minerais presentes nas rochas, como halita, silvita e outros sais evaporíticos, bem como pelo influxo de águas de formação com elevada concentração iônica (CAENN e CHILLINGAR, 1996; THOMAS, 2001).


A dissolução desses sais no fluido de perfuração pode resultar em aumentos progressivos da força iônica do sistema, afetando diretamente o equilíbrio químico do fluido. Esse fenômeno é particularmente relevante em poços que atravessam formações salinas ou sequências estratigráficas com elevada mineralização, onde a interação fluido-rocha promove alterações contínuas na composição química do fluido circulante (DARLEY e GRAY, 1988). Como consequência, variações na salinidade podem impactar propriedades como reologia, filtração, estabilidade coloidal e eficiência dos aditivos químicos.

Em determinados contextos operacionais, a adição controlada de sais, como cloreto de sódio, cloreto de cálcio ou cloreto de potássio, é empregada de forma estratégica para inibir a hidratação e o inchamento de argilas reativas, contribuindo para a estabilidade das paredes do poço e reduzindo problemas de instabilidade mecânica (MITCHELL e MISKA, 2011). No entanto, o aumento excessivo da salinidade, seja por adição deliberada ou por dissolução de sais da formação, pode comprometer o desempenho de polímeros utilizados no controle reológico e de filtração, promovendo a degradação de cadeias poliméricas ou a redução de sua eficiência funcional.

2.2 Unidade de controle de sólidos

A unidade de controle de sólidos integra o sistema de circulação de uma sonda de perfuração e desempenha papel estratégico no tratamento do fluido de perfuração, especialmente no que se refere ao manejo dos cascalhos gerados durante o processo de perfuração. Mais do que um conjunto de equipamentos voltados à recuperação do fluido, essa unidade constitui uma etapa essencial para o controle operacional do poço, para a redução de custos e para a obtenção de informações geológicas fundamentais a partir dos cascalhos provenientes das formações perfuradas (GROSSI, 2020; THOMAS, 2001). A Figura 2.1 apresenta um esquema ilustrativo de uma unidade de controle de sólidos.

Figura 2.1 - Representação ilustrativa do sistema de controle de sólidos.



Fonte: Adaptado de Nascentes, 2019.

Durante a perfuração, o fluido é bombeado a partir dos tanques de superfície, percorre o interior da coluna de perfuração até a broca e retorna à superfície pelo espaço anular, transportando os fragmentos de rocha gerados pela ação mecânica da broca, conhecidos como cascalhos de perfuração (THOMAS, 2001). Esses cascalhos representam não apenas um resíduo do processo, mas também uma fonte primária de informações sobre a litologia, a mineralogia e as condições das formações atravessadas, sendo amplamente utilizados no monitoramento geológico e na tomada de decisões em tempo real durante a perfuração (BOURGOYNE *et al.*, 1986).

Ao atingir a superfície, o fluido carregado de cascalhos é direcionado à fase de tratamento do sistema de circulação, que tem como objetivo principal promover a separação eficiente desses sólidos, preservando as propriedades do fluido e possibilitando sua reutilização. Essa etapa envolve a aplicação sequencial de equipamentos de separação sólidos-líquido,

projetados para remover partículas de diferentes faixas granulométricas, com especial destaque para a remoção inicial e seletiva dos cascalhos de maior tamanho (CAENN *et al.*, 2014; DARLEY e GRAY, 1988).

Nesse contexto, as peneiras vibratórias, constituem o primeiro e mais importante equipamento da unidade de controle de sólidos, seguido por um conjunto de equipamentos que realizam o polimento do fluido, no que diz respeito a presença de sólidos. A função primordial das peneiras é promover a separação inicial dos cascalhos transportados pelo fluido, por meio da vibração mecânica aplicada a telas com aberturas controladas. A eficiência dessa etapa é determinante para o desempenho de todo o sistema subsequente, uma vez que a remoção inadequada dos cascalhos pode comprometer a operação dos equipamentos posteriores e modificar as propriedades do fluido de perfuração (PEREIRA, 2013, CHO *et al.* 2001).

Além da função operacional, as peneiras vibratórias desempenham papel central na seleção e recuperação dos cascalhos para fins de monitoramento geológico nas unidades de controle de sólidos. A coleta sistemática e controlada dos cascalhos retidos nas telas permite a análise detalhada das formações perfuradas, fornecendo informações relevantes sobre mudanças litológicas, presença de hidrocarbonetos, zonas de sobre-pressão e possíveis riscos operacionais. Dessa forma, o adequado controle da separação e do manuseio dos cascalhos nas peneiras contribui diretamente para a segurança do poço e para a otimização das estratégias de perfuração (PETRI, 2017; MITCHELL e MISKA, 2011).

Após a etapa de peneiramento, o fluido segue para equipamentos de separação mais refinados, como desareidores e dessiltadores, responsáveis pela remoção de partículas sólidas de menores dimensões, como areia e silte. Embora essas etapas sejam fundamentais para a manutenção das propriedades do fluido, o controle primário dos cascalhos ocorre predominantemente nas peneiras vibratórias, onde a maior fração sólida gerada pela perfuração é removida e disponibilizada para análise (PETRI, 2017).

A correta operação da unidade de controle de sólidos, com ênfase no desempenho das peneiras vibratórias, permite não apenas a redução do teor de sólidos indesejáveis no fluido de perfuração, mas também o controle mais preciso da geração, transporte e descarte dos cascalhos. Esse controle é essencial para minimizar impactos ambientais, reduzir o consumo de aditivos químicos e garantir a confiabilidade das informações obtidas a partir dos cascalhos, que são amplamente utilizadas por geólogos e engenheiros durante a perfuração (MAGALHÃES, 2015; GROSSI, 2020; CAENN e CHILLINGAR, 1996).

2.2.1 Cascalhos produzidos durante a perfuração

Os cascalhos produzidos durante a perfuração correspondem aos fragmentos sólidos resultantes da fragmentação mecânica das formações rochosas pela ação da broca. Esses materiais são gerados de forma contínua ao longo da perfuração e apresentam características físicas e mineralógicas diretamente relacionadas ao tipo de formação atravessada, às condições operacionais e aos parâmetros de perfuração adotados. Assim, os cascalhos constituem um registro físico imediato do processo de perfuração e da natureza das formações exploradas (FAGUNDES, 2018).

A morfologia, o tamanho e a distribuição granulométrica dos cascalhos são influenciados por diversos fatores, incluindo o tipo de broca, a taxa de penetração, o peso sobre a broca e a interação mecânica com a rocha. Formações mais competentes tendem a gerar fragmentos maiores e mais angulares, enquanto formações mais friáveis ou argilosas podem resultar em partículas mais finas e irregulares. Essas características fornecem subsídios importantes para a interpretação das condições de perfuração e para a identificação de variações litológicas ao longo do poço (FAGUNDES, 2018; BOURGOYNE *et al.*, 1986).

Além de sua origem mecânica, os cascalhos podem sofrer alterações durante o transporte até a superfície, como abrasão, fragmentação secundária e recobrimento por fluido de perfuração. Esses fenômenos podem modificar parcialmente suas características originais, influenciando a representatividade das amostras coletadas. Dessa forma, a análise crítica das condições de transporte e do tempo de residência do cascalho no sistema torna-se essencial para garantir a confiabilidade das informações extraídas a partir desses materiais (MITCHELL e MISKA, 2011, CHO *et al.*, 2001).

Do ponto de vista informacional, os cascalhos desempenham papel central no monitoramento geológico durante a perfuração. A análise sistemática desses fragmentos permite a identificação de mudanças litológicas, a detecção de zonas fraturadas, a indicação de presença de hidrocarbonetos e a avaliação preliminar de propriedades petrofísicas da formação. Essas informações são fundamentais para apoiar decisões operacionais em tempo real, como ajustes na trajetória do poço, na densidade do fluido ou nos parâmetros de perfuração (THOMAS, 2001).

A qualidade das informações obtidas a partir dos cascalhos está diretamente associada à representatividade e à integridade das amostras coletadas. Cascalhos excessivamente fragmentados, contaminados ou misturados a sólidos indesejáveis podem comprometer a interpretação geológica e levar a conclusões imprecisas sobre as formações perfuradas

(MATTA, 2014). Nesse contexto, o controle adequado da geração, do transporte e da separação dos cascalhos assume importância estratégica para a confiabilidade do monitoramento geológico das regiões exploradas.

2.2.1.1 Propriedades morfológicas, cristalográficas e granulométricas

As propriedades intrínsecas dos cascalhos como a morfologia, a cristalografia e distribuição granulométrica não são apenas atributos descritivos, mas parâmetros operacionais decisivos que influenciam diretamente a eficiência de todo o sistema de controle de sólidos e o monitoramento da perfuração. A compreensão detalhada dessas características é fundamental para a seleção e otimização dos equipamentos de separação, especialmente das peneiras vibratórias, e para o desenvolvimento de técnicas de monitoramento mais precisas e automatizadas.

A morfologia das partículas, que engloba forma, arredondamento e textura superficial, é determinada pela interação entre o mecanismo de falha da rocha frente à broca e sua microestrutura mineralógica. Brocas que atuam por cisalhamento, tendem a gerar cascalhos laminados e com superfícies mais lisas, enquanto brocas de dentes cônicos, que fraturam a rocha por impacto e esmagamento, produzem fragmentos mais irregulares e angulares. Partículas angulares possuem maior relação superfície-volume e maior atrito interpartícula, o que pode promover a formação de pontes (*bridging*) nas malhas das peneiras, prejudicando a taxa de separação e aumentando o arraste de fluido com os sólidos rejeitados. Além disso, a forma das partículas influencia diretamente a velocidade de sedimentação dos no fluido e o potencial de formação de camadas no poço (SOUZA, 2024).

A composição cristalográfica e mineralógica da rocha de origem imprime propriedades críticas aos cascalhos, como densidade, dureza e tendência à hidratação ou dispersão. Cascalhos de folhelhos argilosos, por exemplo, podem se hidratar e se dispersar no fluido base água, gerando uma população coloidal de partículas ultrafinas que desafia os equipamentos de separação primária e altera significativamente a reologia do fluido. Por outro lado, cascalhos de arenitos quartzosos, mais densos e abrasivos, impõem maior desgaste mecânico às telas das peneiras e aos demais componentes do sistema de controle de sólidos (BOURGOYNE *et al.*, 1986; RAJA *et al.*, 2017). A presença de minerais com propriedades específicas, como a barita ou argilominerais expansivos, exige ajustes operacionais na peneiração devido às suas características físico-químicas e comportamento no fluido de perfuração (CAENN *et al.*, 2017). Adicionalmente, esses minerais podem ser identificados por

meio de técnicas avançadas de caracterização, permitindo sua detecção como assinaturas mineralógicas em sistemas de monitoramento (BRIDGES & ROBINSON, 2020).

Ainda vale destacar que, a classificação dos fragmentos de rocha em função do tamanho pode ser descrita por diferentes sistemas normativos existentes, sendo os mais utilizados aqueles propostos pela Sociedade Americana de Engenharia Mecânica (ASME) e pela Associação Brasileira de Normas Técnicas (ABNT). Fragmentos com diâmetro superior a 1.000 mm são classificados, segundo a ABNT, como blocos de rocha. Para partículas com diâmetros compreendidos entre 1.000 mm e 200 mm, a classificação corresponde a matacões, enquanto aquelas situadas entre 200 mm e 60 mm são denominadas seixos. Fragmentos com diâmetros entre 60 mm e 2 mm enquadram-se na classe de grânulos.

No sistema da ASME, partículas com diâmetro superior a 2 mm são agrupadas sob a denominação geral de cascalho. Já a faixa granulométrica compreendida entre 2 mm e 0,074 mm é classificada como areia, sendo subdividida pela ABNT em areia grossa ($2 \text{ mm} > d > 0,6 \text{ mm}$), areia média ($0,6 \text{ mm} > d > 0,2 \text{ mm}$) e areia fina ($0,2 \text{ mm} > d > 0,074 \text{ mm}$). Para partículas com diâmetro inferior a 0,074 mm, a ASME adota a classificação de lama, enquanto a ABNT distingue entre silte, para partículas com diâmetros entre 0,06 mm e 0,002 mm, e argila, para aquelas com diâmetros inferiores a 0,002 mm. Por fim, partículas extremamente finas, com comportamento coloidal, são classificadas como colóides no sistema da ASME.

A distribuição granulométrica é, talvez, a propriedade mais diretamente vinculada ao projeto e ao desempenho das peneiras vibratórias. A eficiência de separação de uma tela é uma função da sua abertura de malha e do perfil de tamanho das partículas que a alimentam. Uma ampla distribuição, com presença significativa de partículas próximas ao tamanho da abertura (“partículas *near-mesh*”), é o principal desafio para a separação eficiente, pois aumenta a probabilidade de cegamento parcial da tela e a perda de fluido útil com os sólidos descartados (API, 2014; FORRESTER, 2018). O percentual de finos ($< 75 \mu\text{m}$) é particularmente crítico, pois essas partículas, se não forem removidas por equipamentos subsequentes (como desiltadores ou centrífugas), recirculam no sistema, acumulando-se e degradando progressivamente o desempenho do fluido. Portanto, a análise granulométrica contínua ou frequente do material que passa pela peneira vibratória é uma ferramenta poderosa para diagnosticar a eficácia do corte da tela e a saúde geral do sistema de fluidos (API, 2014).

A conexão direta entre essas propriedades e o monitoramento da perfuração torna-se clara na perspectiva de uma Perfuração Assistida por Dados (*Data-Driven Drilling*). A morfologia e o tamanho dos cascalhos carregados à superfície contêm informações sobre a resposta da formação aos parâmetros da broca. Alterações abruptas nessas propriedades podem

correlacionar-se com mudanças litológicas, transições de fácies ou mesmo com o início de problemas como a geração excessiva de microfissuras e a falha não-ideal da rocha (VAN OORT *et al.*, 2003). Sistemas de imagem e análise automatizadas de cascalhos, baseados em visão computacional, estão sendo desenvolvidos justamente para capturar essas propriedades morfológicas e granulométricas em tempo real, transformando um fluxo de resíduos em um fluxo contínuo de dados geológicos e operacionais (SINGH *et al.*, 2023). Dessa forma, a caracterização avançada das propriedades dos cascalhos deixa de ser uma análise *post-mortem* e passa a integrar um ciclo de controle em tempo real, onde a resposta do sistema de separação (escolha da tela, ajuste de parâmetros da peneira) pode ser otimizada dinamicamente com base no material efetivamente sendo produzido, fechando o ciclo entre a geração do cascalho no fundo do poço e sua gestão eficiente na superfície.

2.2.2 Peneiras vibratórias

As peneiras vibratórias, constituem o principal e mais crítico equipamento da unidade de controle de sólidos, sendo responsáveis pela primeira etapa de separação sólido-líquido no sistema de circulação de fluidos de perfuração (ASME, 2005). Sua função é remover, de forma seletiva e contínua, os cascalhos de maior tamanho transportados pelo fluido de perfuração antes que este siga para os equipamentos subsequentes de separação mais fina. A eficiência dessa etapa inicial é determinante para o desempenho global do sistema de controle de sólidos, uma vez que a remoção inadequada dos cascalhos pode resultar no aumento do teor de sólidos finos no fluido, comprometendo suas propriedades físico-químicas e elevando os custos operacionais (DARLEY e GRAY, 1988; THOMAS, 2001). A Figura 2.2 apresenta uma ilustração de uma peneira vibratória industrial.

Figura 2.2 – Ilustração de uma peneira vibratória industrial linear horizontal



Fonte: Adaptado de GN Separation, 2026.

Do ponto de vista operacional, as peneiras vibratórias consistem basicamente em uma estrutura mecânica equipada com uma ou mais telas tensionadas, submetidas a movimentos vibratórios controlados. O fluido de perfuração proveniente do poço é distribuído sobre a superfície da tela, permitindo que a fase líquida atravessasse as aberturas da malha, enquanto os sólidos com dimensões superiores à abertura nominal da tela são retidos e descartados. Esse processo depende diretamente da interação entre as características dos cascalhos, as propriedades do fluido e os parâmetros operacionais do equipamento (CHO et al., 2001; PEREIRA, 2013).

A seleção adequada das telas é um dos fatores mais relevantes para o desempenho das peneiras vibratórias. As telas são classificadas de acordo com a abertura de malha, geralmente expressa conforme as normas API, e devem ser escolhidas considerando-se a distribuição granulométrica dos cascalhos, a vazão do fluido e as condições operacionais do poço. Telas com aberturas muito grandes resultam em baixa eficiência de separação, permitindo a passagem excessiva de sólidos para as etapas subsequentes, enquanto telas excessivamente finas podem sofrer cegamento, reduzir a capacidade de processamento e aumentar o arraste de fluido com os sólidos descartados (API, 2014; FORRESTER, 2018).

O movimento vibratório aplicado às peneiras tem como objetivo principal promover o transporte dos cascalhos ao longo da tela e aumentar a taxa de passagem do fluido (Barbosa, 2018). Esse movimento pode assumir diferentes configurações, como vibração linear, elíptica ou circular, cada uma apresentando vantagens específicas em termos de capacidade de processamento, eficiência de separação e controle do transporte dos sólidos. A escolha do tipo de movimento e de seus parâmetros operacionais, como frequência, amplitude e ângulo de inclinação da tela, influencia diretamente o tempo de residência dos cascalhos sobre a superfície peneirante e, conseqüentemente, a eficiência do processo (CHO et al., 2001; ASME, 2005).

Além dos parâmetros mecânicos, o desempenho das peneiras vibratórias é fortemente afetado pelas propriedades do fluido de perfuração. Fluidos com elevada viscosidade ou alto teor de sólidos finos tendem a reduzir a taxa de drenagem através da tela, aumentando o risco de cegamento e diminuindo a eficiência de separação. Da mesma forma, a presença de partículas com dimensões próximas à abertura da malha, conhecidas como partículas *near-mesh*, representa um dos principais desafios operacionais, pois essas partículas apresentam alta probabilidade de se alojar nas aberturas da tela, prejudicando o processo de separação (API, 2014; DARLEY e GRAY, 1988).

2.2.2.1 Princípio de funcionamento

O funcionamento das peneiras vibratórias baseia-se na separação mecânica sólido-líquido promovida pela combinação entre diferença de tamanho das partículas, movimento vibratório controlado e geometria da superfície peneirante. A mistura proveniente do processo de perfuração, composta pelo fluido de perfuração e pelos cascalhos gerados pela ação da broca, é inicialmente direcionada a um tanque de alimentação localizado na entrada do equipamento. Esse tanque é dotado de um vertedouro responsável por distribuir o fluido por transbordamento de maneira homogênea ao longo da largura inicial da tela, garantindo uma alimentação uniforme e o melhor aproveitamento da área efetiva de peneiramento (GUERREIRO *et al.*, 2017).

Uma vez sobre a tela, a separação sólido-líquido ocorre em função do movimento vibratório imposto ao conjunto estrutural da peneira. Esse movimento é gerado por motores vibratórios, que induzem oscilações periódicas capazes de submeter a mistura a forças inerciais que favorecem a drenagem do fluido e o transporte dos sólidos. Quando o movimento da tela é direcionado para cima, a inércia faz com que o fluido e as partículas com dimensões inferiores à abertura da malha atravessem a tela, intensificando a separação. Por outro lado, quando o movimento é direcionado para baixo, os sólidos retidos perdem momentaneamente o contato com a superfície peneirante e são projetados para frente, em direção à zona de descarga. Dessa forma, o movimento vibratório exerce simultaneamente duas funções essenciais: favorecer a passagem do líquido pela tela e promover o deslocamento contínuo dos sólidos retidos ao longo do equipamento (ASME, 2005).

O tipo de movimento imposto à peneira vibratória exerce influência direta sobre o desempenho do processo de separação. Os principais tipos de movimento empregados industrialmente são os movimentos circular, elíptico (balanceado e não balanceado) e linear. Nas peneiras de movimento circular, um único motovibrador é instalado no centro de gravidade do cesto, gerando um deslocamento orbital que favorece o transporte dos sólidos sobre a tela. Quando o motovibrador é posicionado fora do centro de gravidade, obtém-se o movimento elíptico não balanceado, no qual o eixo maior da elipse pode dificultar o descarte dos sólidos, exigindo a operação do equipamento com inclinação descendente para compensar esse efeito (ASME, 2005; DORRY, 2010).


O movimento linear é produzido por dois motovibradores operando em contra-rotação, gerando forças alinhadas que promovem maior eficiência de drenagem do fluido e transporte dos sólidos, mesmo sob inclinações mais elevadas. Esse tipo de movimento possibilitou a

utilização de telas com aberturas menores, como as classificadas como API 200, representando um avanço significativo na eficiência de separação. Já o movimento elíptico balanceado, obtido por meio da disposição angular dos motovibradores em contra-rotação, combina boa capacidade de transporte de sólidos com elevada eficiência de separação sólido-líquido, além de impor esforços menos abruptos às telas, reduzindo o desgaste mecânico e aumentando sua vida útil (ASME, 2005).

Além do tipo de movimento, a inclinação do cesto da peneira e a configuração do número de telas constituem variáveis operacionais relevantes no princípio de funcionamento do equipamento. As peneiras podem operar com inclinação ascendente, plana ou descendente em relação ao deslocamento dos sólidos, bem como empregar uma ou mais telas dispostas em série. Essas configurações afetam diretamente o tempo de residência dos cascalhos sobre a superfície peneirante, a taxa de drenagem do fluido e a eficiência global do peneiramento. Muitos equipamentos modernos permitem o ajuste dinâmico da inclinação do cesto, possibilitando a adaptação às condições operacionais do poço (BARBOSA, 2018; HOBEROCK, 1980).

Do ponto de vista do comportamento do material sobre a tela, o peneiramento vibratório apresenta duas regiões distintas, como demonstrado na Figura 2.3. A região inicial, próxima à alimentação, é conhecida como região de líquido ou região de piscina, caracterizada pela presença de uma lâmina contínua de fluido sobre a tela, onde predomina a drenagem da fase líquida (RAJA *et al.*, 2012; HOBEROCK, 1980). À medida que o fluido é drenado, estabelece-se a região de secagem dos sólidos, na qual os cascalhos retidos passam a se deslocar predominantemente em regime “seco”, sendo conduzidos até a extremidade de retirada dos sólidos. A extensão e a dinâmica dessas regiões dependem das propriedades do fluido, da distribuição granulométrica dos sólidos e dos parâmetros operacionais da peneira (DORRY, 2010).

Figura 2.3 - Mapeamento das regiões do processo de peneiramento vibratório.



Fonte: Adaptado de Barbosa, 2018.

2.2.2.2 Desempenho do processo de separação por peneiramento vibratório

O desempenho do processo de separação por peneiramento vibratório constitui um dos pilares do sistema de controle de sólidos durante a perfuração de poços de petróleo, uma vez que influencia diretamente a eficiência de remoção dos cascalhos, a recuperação do fluido de perfuração e a preservação das propriedades físico-químicas do sistema. Um peneiramento ineficiente resulta no acúmulo progressivo de sólidos finos no fluido, elevando parâmetros como viscosidade aparente, força gel e densidade, além de aumentar o consumo de aditivos químicos e o desgaste dos equipamentos localizados a jusante do sistema de circulação (ASME, 2005; HOBEROCK, 1980).

A avaliação do desempenho das peneiras vibratórias é tradicionalmente baseada em indicadores como eficiência de separação, capacidade de processamento, taxa de recuperação de fluido e perda de sólidos úteis. A eficiência de separação está associada à capacidade da tela em reter partículas sólidas acima de um determinado tamanho de corte, enquanto permite a passagem do fluido e de partículas finas desejáveis. Já a capacidade de processamento refere-se à vazão máxima de fluido que pode ser tratada sem que ocorra inundação excessiva da tela ou perda significativa de sólidos pelo descarte (RAJA *et al.*, 2012).

Durante a operação, forma-se sobre a tela uma camada de sólidos, frequentemente denominada leito de partículas, cuja espessura e comportamento dinâmico exercem papel fundamental no desempenho do processo. Um leito excessivamente espesso aumenta a resistência à drenagem do fluido, reduz a área efetiva de peneiramento e favorece a formação da região de piscina, comprometendo a eficiência do deságue. Em contrapartida, um leito muito fino pode resultar em perda de partículas maiores, reduzindo a eficiência de retenção e aumentando a recirculação de sólidos indesejáveis no sistema (KING, 2001).

Além disso, características dos sólidos, como forma, densidade e distribuição granulométrica, afetam diretamente o transporte sobre a tela e o grau de obstrução das aberturas, fenômeno conhecido como *blinding* (HOBEROCK, 1980). A interação entre o regime vibratório, as propriedades do fluido e a morfologia dos cascalhos determina o equilíbrio entre as regiões de piscina e de secagem dos sólidos, sendo este equilíbrio essencial para a operação estável das peneiras vibratórias.

Dessa forma, o desempenho do peneiramento vibratório não pode ser atribuído a um único parâmetro isolado, mas sim ao conjunto de variáveis operacionais e de processo, cuja compreensão integrada é indispensável para a otimização do controle de sólidos. Estudos recentes, inclusive baseados em simulações numéricas e no método dos elementos discretos,

têm contribuído para o entendimento do comportamento dinâmico dos sólidos sobre a tela, evidenciando a complexidade do processo (SUN *et al.*, 2024).

2.2.2.3 Variáveis operacionais

O desempenho do peneiramento vibratório é fortemente influenciado por um conjunto de variáveis operacionais que atuam de forma interdependente (ASME, 2005). O controle adequado dessas variáveis é essencial para garantir elevada eficiência de separação, maximização da recuperação de fluido e aumento da vida útil das telas. A seguir são apresentadas variáveis

- **Vibração**

A vibração consiste em oscilações mecânicas impostas ao cesto da peneira, caracterizadas por frequências relativamente elevadas e amplitudes moderadas, capazes de modificar o comportamento do leito de partículas sobre a tela (GOLOVANEVSKIY *et al.*, 2011). A intensidade da vibração depende da rotação dos motovibradores, da massa e excentricidade dos corpos excêntricos e da massa total do cesto de peneiramento.

Na literatura, a intensidade vibratória é frequentemente expressa em termos de força-g, definida como a razão entre a aceleração imposta ao cesto e a aceleração da gravidade. Esse parâmetro é diretamente proporcional à frequência e à amplitude do movimento vibratório, sendo amplamente utilizado como referência operacional em peneiras vibratórias industriais (ASME, 2005). O aumento da força-g tende a intensificar o transporte dos sólidos sobre a tela, reduzindo o tempo de residência e favorecendo o deságue. Entretanto, valores excessivos podem resultar em desgaste acelerado das telas, fragmentação dos cascalhos e aumento da perda de fluido junto aos sólidos descartados (DORRY, 2010). Estudos baseados em simulações numéricas demonstram que o aumento da frequência de vibração está diretamente relacionado ao aumento da velocidade de transporte dos sólidos, em concordância com observações realísticas observadas.

- **Vazão de alimentação**

A vazão de alimentação do fluido de perfuração exerce influência direta sobre o desempenho hidráulico das peneiras vibratórias, sendo um dos principais fatores responsáveis por variações na eficiência de separação sólido-líquido. À medida que a vazão aumenta, ocorre

a elevação do volume de fluido que se acumula sobre a superfície da tela, resultando na elevação do nível da região de piscina (RAJA *et al.*, 2012)

O aumento da altura dessa região promove maior resistência ao escoamento do fluido através da malha, dificultando o processo de deságue e reduzindo a capacidade de retenção dos sólidos. Como consequência, há maior probabilidade de transporte excessivo de fluido juntamente com os cascalhos, além da passagem de partículas sólidas finas para as etapas subsequentes do sistema de controle de sólidos (RAJA *et al.*, 2012; HOBEROCK, 1980). Em regimes de vazão elevada, o avanço acelerado do fluido sobre a tela pode exceder a capacidade de processamento do equipamento, levando à sobrecarga operacional. Esse cenário compromete a eficiência global da peneira vibratória e pode resultar em perdas de fluido de perfuração, aumento do consumo de aditivos e redução da vida útil das telas (DORRY, 2010). Dessa forma, o controle adequado da vazão de alimentação é fundamental para garantir condições operacionais estáveis e manter a eficiência do processo de separação.

- **Inclinação e abertura da tela da peneira**

A inclinação do cesto influencia diretamente o tamanho das regiões de piscina e de secagem dos sólidos. Inclinações descendentes favorecem o transporte rápido dos cascalhos até o ponto de descarte, porém tendem a dificultar a drenagem do fluido, aumentando o risco de perdas de líquido juntamente com os sólidos (ASME, 2005). Já inclinações do tipo positivas, por outro lado, facilitam a formação da região de piscina e o escoamento do fluido através da tela, mas oferecem maior resistência ao deslocamento dos sólidos, o que pode reduzir a vida útil da tela devido ao aumento do atrito (DORRY, 2010). Sistemas de controle automático de inclinação têm sido propostos para ajustar dinamicamente essa variável em função da vazão de alimentação e das condições operacionais (SCOTT, 2006).

A abertura da tela deve ser selecionada de acordo com a granulometria dos sólidos e com os aditivos presentes no fluido de perfuração. Telas com aberturas próximas ao tamanho das partículas favorecem o fenômeno de *blinding*, reduzindo a área efetiva de peneiramento e comprometendo o desempenho do processo (HOBEROCK, 1980).

- **Granulometria dos sólidos**

A distribuição granulométrica, a forma e a concentração dos sólidos na alimentação constituem variáveis fundamentais para o desempenho do peneiramento vibratório. A presença de uma fração significativa de partículas finas aumenta substancialmente a viscosidade aparente

e a resistência ao escoamento do fluido portador através da malha. Este fenômeno resulta no incremento da altura do leito de sólidos (ou região de “piscina”) sobre a tela, o que reduz diretamente a capacidade de processamento da unidade (ASME, 2005). Paralelamente, partículas com dimensões muito próximas ao tamanho da abertura da malha, classificadas como *near-size*, apresentam uma elevada propensão ao entupimento (*blinding*). A obstrução dos orifícios diminui a área ativa de classificação, comprometendo a eficiência da separação, promovendo a perda de finos pelo extravasor e acelerando o desgaste por abrasão do meio filtrante (HOBROCK, 1980).

Contudo, os desafios para uma caracterização precisa e uniforme da granulometria de alimentação na peneiras reforça a complexidade do sistema, pois a vazão de cascalho que chega às peneiras vibratórias, que está diretamente associada à taxa de avanço da perfuração (penetração da broca) e às condições hidráulicas do poço. Variações nesse fluxo sólido-fluido podem indicar mudanças granulométricas e morfológica, (BOURGOYNE *et al.*, 1986; MITCHELL *et al.*, 2011).

- **Viscosidade do fluido de perfuração**

As propriedades reológicas do fluido de perfuração exercem papel determinante no desempenho do peneiramento vibratório, influenciando diretamente os mecanismos de drenagem, transporte e separação sólido-líquido sobre a tela. Parâmetros como viscosidade aparente, viscosidade plástica, limite de escoamento e força gel governam a capacidade do fluido de atravessar a malha sob ação da vibração, bem como o comportamento do leito de sólidos formado sobre a peneira. O aumento da viscosidade e da força gel eleva a resistência ao escoamento do fluido portador, dificultando sua drenagem através da tela e promovendo o acúmulo de fluido na região de piscina. Como consequência, observa-se a redução da capacidade operacional da peneira, o aumento do arraste de fluido com os sólidos descartados e a diminuição da eficiência global do processo de separação (RAJA *et al.*, 2012; CAENN *et al.*, 2017; ASME, 2005).

Em condições de elevada viscosidade, o escoamento do fluido sobre a tela tende a assumir um regime mais laminar e menos permeável, reduzindo a taxa de percolação e ampliando o tempo de residência dos sólidos sobre a malha. Esse efeito é particularmente crítico na presença de partículas finas, que contribuem para o aumento da viscosidade aparente e para o selamento parcial dos orifícios da tela, agravando fenômenos como o cegamento (*blinding*) e a perda de eficiência de corte. Além disso, forças gel elevadas dificultam a liberação do fluido aprisionado entre os sólidos, aumentando o teor de fluido nos cascalhos descartados e

impactando negativamente tanto o custo operacional quanto a sustentabilidade do processo (HOBEROCK, 1980; API, 2014).

A adição de aditivos químicos ao fluido de perfuração, embora essencial para o controle reológico, estabilidade do poço, inibição de argilas e transporte de cascalhos, pode intensificar esses efeitos adversos no peneiramento vibratório. Polímeros viscosificantes, argilas organofílicas, agentes de controle de filtração e surfactantes alteram significativamente o comportamento reológico do fluido, muitas vezes de forma não linear, especialmente sob diferentes taxas de cisalhamento. Em sistemas base água, por exemplo, a presença de polímeros de alto peso molecular pode aumentar a viscosidade de baixo cisalhamento, favorecendo o transporte no poço, mas penalizando severamente a drenagem sobre a peneira. Já em fluidos base óleo ou sintéticos, emulsificantes e agentes molhantes podem modificar a tensão interfacial e a afinidade fluido-sólido, impactando a eficiência de separação e a retenção de fluido nos sólidos (BOURGOYNE *et al.*, 1986; RAJA *et al.*, 2017).

Nesse contexto, o monitoramento integrado e o controle das variáveis mecânicas, físicas, químicas e reológicas da mistura sólido-líquido assume papel estratégico na eficiência das peneiras vibratórias, permitindo a otimização do sistema de controle de sólidos, a redução de perdas de fluido e a melhoria da eficiência operacional ao longo da perfuração (API, 2014).

2.2.3 *Mud Logging*

O sistema de *mud logging* constitui um dos principais métodos de monitoramento em tempo real durante a perfuração de poços de petróleo e gás, sendo responsável pela aquisição, integração e interpretação contínua de dados geológicos, operacionais e geoquímicos provenientes do fluido de perfuração e dos cascalhos retornados à superfície. Diferentemente de outras técnicas de perfilagem realizadas após a perfuração de um intervalo específico, o *mud logging* fornece informações quase instantâneas sobre as formações atravessadas, desempenhando papel estratégico na tomada de decisões operacionais e na mitigação de riscos durante a perfuração (BOURGOYNE *et al.*, 1986; THOMAS, 2001).

De forma geral, o sistema de *mud logging* é composto por um conjunto de sensores, equipamentos de aquisição de dados e procedimentos analíticos instalados na unidade de perfuração, normalmente associados à unidade de controle de sólidos. O fluido de perfuração, ao retornar do poço carregando os cascalhos e os fluidos de formação, constitui a principal fonte de informação do sistema. A partir desse retorno, são monitorados parâmetros como vazão, densidade, temperatura, composição gasosa, taxa de penetração, torque, peso sobre a broca,

além das características físicas e mineralógicas dos cascalhos (DOVETON, 1994; SCHLUMBERGER, 2004).

Um dos pilares do *mud logging* é a análise sistemática dos cascalhos de perfuração. Após sua separação primária nas peneiras vibratórias, os cascalhos são coletados, lavados, secos e analisados quanto à sua litologia, granulometria, morfologia, cor, presença de hidrocarbonetos visíveis e indícios de fraturamento. Essas análises permitem identificar mudanças litológicas, contatos estratigráficos, zonas de maior porosidade ou fraturamento e possíveis intervalos produtores, fornecendo subsídios importantes para o acompanhamento geológico do poço (ELLIS e SINGER, 2007; PETRI, 2017).

Além das análises geológicas, o *mud logging* desempenha papel essencial no monitoramento de segurança operacional. A detecção de gases dissolvidos no fluido de perfuração, como metano, etano, propano e hidrocarbonetos mais pesados, permite a identificação precoce de influxos de formação e zonas de sobrepressão, contribuindo para a prevenção de eventos críticos como *kicks* e *blowouts*. Sistemas modernos de *mud logging* empregam cromatografia gasosa e sensores contínuos de gás total, integrando essas informações com parâmetros operacionais para uma interpretação mais robusta do comportamento do poço (BOURGOYNE *et al.*, 1986; CAENN e CHILLINGAR, 1996).

A confiabilidade das informações geradas pelo *mud logging* está diretamente associada à qualidade do sistema de controle de sólidos e, em particular, ao desempenho das peneiras vibratórias. Cascalhos excessivamente fragmentados, contaminados por sólidos finos ou misturados devido à ineficiência do peneiramento podem comprometer a representatividade das amostras analisadas. Além disso, variações no tempo de transporte dos cascalhos desde o fundo do poço até a superfície introduzem incertezas na correlação profundidade e o tempo, exigindo correções baseadas em parâmetros operacionais do poço (MITCHELL e MISKA, 2011).

Tradicionalmente, grande parte das análises de *mud logging* depende de inspeções visuais e interpretações qualitativas realizadas por geólogos e técnicos especializados. Embora esse método seja amplamente consolidado na indústria, ele está sujeito a limitações relacionadas à subjetividade do observador, à variabilidade das condições operacionais e à dificuldade de padronização dos critérios de análise. Essas limitações tornam-se mais evidentes em ambientes de perfuração complexos, como poços de alta inclinação, poços horizontais e operações em águas profundas, onde o volume de dados gerados é elevado e a tomada de decisão em tempo real é crítica (ELLIS e SINGER, 2007).

Nesse contexto, observa-se uma tendência crescente de integração do *mud logging* com sistemas automatizados de aquisição e análise de dados, alinhados aos conceitos de *Digital*

Oilfield e Data-Driven Drilling. Tecnologias baseadas em sensores avançados, aprendizado de máquina e visão computacional vem sendo investigadas com o objetivo de reduzir a subjetividade das análises, aumentar a frequência de amostragem e transformar os cascalhos de perfuração em uma fonte contínua e quantitativa de informações operacionais e geológicas (KARIMI, 2013; GROSSI *et al.*, 2023).

A aplicação de técnicas de visão computacional no contexto do *mud logging* representa uma evolução natural dos métodos tradicionais, permitindo a caracterização automatizada da granulometria, morfologia e vazão de cascalhos diretamente nas peneiras vibratórias. Essa abordagem possibilita a correlação em tempo real entre parâmetros de perfuração, desempenho do sistema de controle de sólidos e características dos cascalhos gerados, ampliando significativamente o potencial informacional do *mud logging* e contribuindo para uma tomada de decisão mais rápida, objetiva e baseada em dados (GROSSI, 2020; MATTA, 2014).

2.2.4 Análise e monitoramento de cascalhos

A análise e o monitoramento dos cascalhos de perfuração constituem uma das principais fontes de informação geológica e operacional durante a perfuração de poços de petróleo e gás. Esses fragmentos sólidos, gerados continuamente pela ação da broca sobre as formações rochosas, transportam para a superfície informações diretas sobre a litologia, a estrutura e o comportamento mecânico das rochas atravessadas, além de refletirem as condições operacionais impostas ao sistema de perfuração. Dessa forma, os cascalhos representam um elo fundamental entre os fenômenos que ocorrem no fundo do poço e as decisões tomadas em superfície (BOURGOYNE *et al.*, 1986; DOVETON, 1994).

Historicamente, a análise de cascalhos tem sido empregada como ferramenta básica de acompanhamento geológico, especialmente em intervalos onde técnicas de perfilagem elétrica ou nuclear apresentam limitações operacionais ou custos elevados. A observação sistemática das amostras permite a identificação de mudanças litológicas, contatos estratigráficos, zonas fraturadas, intervalos com potencial presença de hidrocarbonetos e indícios de variações de pressão de poros. Além disso, variações abruptas nas características dos cascalhos podem indicar eventos operacionais relevantes, como desgaste excessivo da broca, mudanças no mecanismo de ruptura da rocha ou instabilidades na parede do poço (ELLIS e SINGER, 2007).

Do ponto de vista operacional, o monitoramento dos cascalhos fornece subsídios importantes para a avaliação da eficiência do processo de perfuração. A taxa de geração de cascalhos, sua granulometria e morfologia estão diretamente associadas à taxa de penetração

da broca, ao peso aplicado, à rotação e às propriedades do fluido de perfuração. Um aumento inesperado na produção de finos, por exemplo, pode estar relacionado à fragmentação excessiva da rocha, à dispersão de argilas reativas ou à degradação mecânica dos fragmentos durante o transporte até a superfície. Esses fenômenos impactam diretamente o desempenho do sistema de controle de sólidos e a estabilidade das propriedades reológicas do fluido (MITCHELL e MISKA, 2011; DARLEY e GRAY, 1988).

A qualidade das informações obtidas a partir dos cascalhos depende fortemente da representatividade das amostras coletadas (MATTA, 2014). Fatores como o tempo de transporte dos fragmentos desde o fundo do poço até a superfície, a abrasão durante o escoamento no espaço anular, a fragmentação secundária e a eficiência do peneiramento influenciam significativamente as características finais das partículas analisadas. Assim, a correta correlação entre profundidade perfurada e cascalho coletado exige o conhecimento das condições hidráulicas do poço, da vazão de circulação e do volume anular, de modo a minimizar incertezas na interpretação dos dados (BOURGOYNE *et al.*, 1986; THOMAS, 2001).

Tradicionalmente, a análise de cascalhos baseia-se em procedimentos predominantemente qualitativos, realizados por especialistas em geologia de poços. Esses procedimentos incluem inspeção visual, descrição macroscópica, classificação granulométrica aproximada, análise de fluorescência sob luz ultravioleta e testes simples de solubilidade ou reação química. Embora amplamente difundidas, essas técnicas apresentam limitações relacionadas à subjetividade do observador, à baixa frequência de amostragem e à dificuldade de padronização entre diferentes operadores e unidades de perfuração (DOVETON, 1994; ELLIS e SINGER, 2007).

Com o avanço das operações de perfuração em ambientes cada vez mais complexos, como poços horizontais, poços de grande profundidade e operações em águas profundas, cresce a demanda por métodos de monitoramento de cascalhos mais objetivos, quantitativos e contínuos. Nesse contexto, técnicas automatizadas de análise vêm sendo investigadas com o objetivo de reduzir a dependência da interpretação manual e ampliar a confiabilidade das informações extraídas dos fragmentos de rocha. Métodos baseados em análise de imagem, processamento digital e aprendizado de máquina demonstram um grande potencial para a caracterização granulométrica e morfológica dos cascalhos em tempo quase real (MITCHELL e MISKA, 2011; KARIMI, 2013)

A integração do monitoramento de cascalhos com o sistema de controle de sólidos, especialmente nas peneiras vibratórias, representa uma oportunidade estratégica para a aquisição contínua de dados. As peneiras constituem o primeiro ponto de contato dos cascalhos

com a superfície, oferecendo um ambiente favorável para a implementação de sistemas de monitoramento não intrusivos. A observação direta do fluxo de sólidos sobre as telas permite não apenas a caracterização das partículas, mas também a estimativa da vazão mássica de cascalhos e a avaliação indireta do desempenho da perfuração e da eficiência do peneiramento (ASME, 2005).

Além do aspecto geológico, o monitoramento sistemático dos cascalhos possui implicações diretas na gestão operacional e ambiental. A quantificação da produção de cascalhos e do teor de fluido retido nos sólidos descartados permite otimizar a escolha das telas, ajustar parâmetros operacionais das peneiras vibratórias e reduzir perdas de fluido de perfuração. Essas ações contribuem para a diminuição do consumo de aditivos químicos, para a redução do volume de resíduos gerados e para a mitigação dos impactos ambientais associados às operações de perfuração (API, 2014).

2.3 Visão computacional aplicada a análise de cascalhos

A visão computacional constitui uma área interdisciplinar que integra fundamentos da ciência da computação, matemática aplicada, estatística e engenharia, com o objetivo de capacitar sistemas computacionais a extrair informações relevantes a partir de imagens e vídeos de forma automática. Diferentemente do simples processamento de imagens, que se concentra na melhoria visual e na manipulação de sinais bidimensionais, a visão computacional busca interpretar semanticamente o conteúdo visual, permitindo a identificação, a mensuração e a classificação de objetos e fenômenos presentes em uma cena (GONZALEZ e WOODS, 2018).

Nas últimas décadas, o avanço do poder computacional, aliado à evolução de sensores ópticos, sistemas de aquisição de imagem e técnicas de aprendizado de máquina, impulsionou a aplicação da visão computacional em ambientes industriais complexos. Em operações de petróleo e gás, essa tecnologia vem sendo explorada para monitoramento de processos, inspeção automática, detecção de anomalias e suporte à tomada de decisão em tempo real. A capacidade de operar de forma contínua, não intrusiva e com elevada repetibilidade torna a visão computacional particularmente atrativa para cenários nos quais métodos tradicionais de medição são limitados, perigosos ou economicamente inviáveis (SONKA *et al.*, 2015).

No contexto da perfuração de poços, a visão computacional apresenta potencial significativo para a análise de cascalhos, uma vez que esses materiais estão naturalmente expostos em superfície durante o processo de controle de sólidos. A aquisição contínua de imagens sobre peneiras vibratórias permite a observação direta do fluxo de partículas,

viabilizando a caracterização geométrica, a estimativa de distribuição granulométrica e a avaliação da vazão de sólidos em tempo quase real. Essa abordagem reduz a dependência de amostragem manual e introduz um novo paradigma de monitoramento baseado em dados visuais objetivos e quantificáveis (Matta, 2019).

Inicialmente, GROSSI *et al.* (2019) estabeleceram uma prova de conceito para a análise de escoamento de sólidos utilizando técnicas de Deep Learning e Clustering. Nesta etapa preliminar, o estudo utilizou cereais (milho, arroz, feijão) para simular o escoamento em calha vibratória, aplicando a rede neural convolucional (CNN) AlexNet para identificação dos grãos e o algoritmo k-means para estimativas da vazão de sólidos. Os resultados mostraram-se promissores para a contagem de grãos e estimativa de vazão, validando o potencial da visão computacional para substituir análises manuais, embora ainda em fase inicial de testes com materiais análogos.

A complexidade das análises aumentou ao transpor os métodos para fragmentos de rocha reais. Grossi *et al.* (2022) aplicaram a Transformada Discreta de Fourier Bidimensional (DFT-2D) para a detecção e segmentação de bordas de fragmentos de mármore, granito e cascalho de perfuração. Além da detecção, o trabalho inovou ao utilizar redes neurais convolucionais (CNN) com a técnica de *transfer learning* na arquitetura AlexNet para classificar os cascalhos por faixas de tamanho. O uso de um banco de dados tratado, com sub-imagens de 600x600 pixels, elevou a acurácia da classificação para 94%, demonstrando a viabilidade de identificar cascalhos de desmoronamento (tipicamente maiores) de forma automática e não invasiva, além de conseguir resultados de morfologia com descritores geométricos e propriedades estatísticas.

Grossi *et al.* (2023) utilizaram um protótipo operando com suspensão de areia e goma xantana a 0,1% para gerar um banco de 11.140 imagens. O estudo aplicou a rede neural U-Net para realizar a segmentação semântica, classificando as imagens pixel a pixel para delimitar com exatidão o material particulado sobre a tela. O modelo obteve alto desempenho na segmentação, alcançando acurácia de teste de 99,8% e MeanIoU de 94,2%. Os autores concluíram que a arquitetura U-Net é altamente promissora para o aprendizado dessas características visuais, destacando o potencial para futuras aplicações em predições em peneiras vibratórias.

A consolidação das metodologias baseadas em processamento clássico de imagens foi apresentada por Grossi *et al.* (2023), que detalharam o desenvolvimento de um software completo para monitoramento em tempo real. Utilizando a DFT-2D para segmentação morfológica e detectores de pontos de interesse (MSER, Harris e SURF) para cálculo da

velocidade, o sistema foi capaz de estimar a área preenchida da peneira com erros inferiores a 4% e a velocidade de deslocamento com desvios menores que 10%. A robustez do método foi validada em diferentes condições de vibração e tipos de rocha, confirmando a capacidade do software em operar de forma autônoma sem intervenção humana.

Sistemas de visão computacional podem ser integrados a arquiteturas de monitoramento em tempo real, combinando dados visuais com variáveis operacionais. Essa integração amplia a capacidade de correlação entre o comportamento dos cascalhos e o desempenho do processo de perfuração, contribuindo para estratégias de otimização operacional e detecção precoce de eventos indesejáveis, como instabilidades da formação ou falhas no sistema de controle de sólidos, em especial a vazão de cascalhos em peneiras vibratórias.

2.3.1 Análise e segmentação de imagens

A análise de imagens corresponde a um conjunto de técnicas voltadas à extração de informações quantitativas e qualitativas a partir de imagens digitais. Essas técnicas operam sobre representações matriciais de intensidade luminosa, normalmente organizadas em níveis de cinza ou em canais de cor, e têm como objetivo identificar padrões, estruturas geométricas e relações espaciais entre os elementos presentes na imagem. Em aplicações de engenharia, a análise de imagens constitui a etapa fundamental para a transformação de dados visuais brutos em descritores mensuráveis (GONZALEZ e WOODS, 2018).

O processo de análise de imagens geralmente envolve uma sequência estruturada de etapas, iniciando-se pela aquisição da imagem, seguida de pré-processamento, segmentação, extração de características e, eventualmente, classificação ou regressão. O pré-processamento tem como finalidade melhorar a qualidade da imagem e reduzir interferências, como ruído, variações de iluminação e distorções ópticas. Técnicas comuns incluem filtragem espacial, normalização de contraste e correção geométrica, que contribuem para aumentar a robustez das etapas subsequentes (SONKA *et al.* 2015).

A etapa de aquisição da imagem corresponde ao processo de captura dos dados visuais por meio de sensores ópticos, normalmente câmeras digitais, e constitui a base de todo o sistema de análise. A qualidade das imagens adquiridas influencia diretamente o desempenho das etapas subsequentes, sendo fortemente dependente de fatores como resolução espacial, taxa de aquisição, campo de visão, profundidade de campo e condições de iluminação (MATTA, 2014). Em ambientes industriais, a aquisição deve ser projetada de modo a minimizar efeitos adversos, como sombras, reflexos, vibração mecânica e variações abruptas de luminosidade. No contexto

de peneiras vibratórias, desafios adicionais incluem o movimento contínuo das partículas, a presença de fluido residual e a formação de aglomerados, o que exige estratégias de posicionamento e proteção dos sensores para assegurar a estabilidade do sinal visual.

Após a aquisição, a imagem passa por uma etapa de pré-processamento, cujo objetivo é melhorar a qualidade dos dados e reduzir interferências que possam comprometer a análise. O pré-processamento envolve a aplicação de técnicas de filtragem espacial e temporal para atenuação de ruído, correção de distorções ópticas introduzidas pela lente, normalização de iluminação e realce de contraste. Em aplicações dinâmicas, como o escoamento de cascalhos, essa etapa é essencial para lidar com variações na aparência das partículas causadas por umidade, deposição de fluido e mudanças no ângulo de observação. Um pré-processamento adequado contribui para aumentar a robustez da segmentação e reduzir a propagação de erros ao longo da cadeia de processamento (FILHO e NETO, 1999; GONZALEZ e WOODS, 2018).

A segmentação representa uma das etapas mais críticas da análise de imagens, pois tem como finalidade separar os objetos de interesse do fundo da cena. No caso específico da análise de cascalhos, a segmentação envolve a identificação das partículas sólidas presentes sobre a superfície da peneira vibratória, isolando-as do fundo da tela e do fluido de perfuração remanescente. Métodos clássicos de segmentação incluem técnicas baseadas em limiarização de intensidade, detecção de bordas e crescimento de regiões, enquanto abordagens mais avançadas empregam modelos estatísticos ou algoritmos de aprendizado de máquina. A escolha do método depende do grau de complexidade da cena e da variabilidade das condições operacionais, sendo comum a combinação de diferentes técnicas para aumentar a precisão e a estabilidade do processo (HARALICK e SHAPIRO, 1992).

Uma vez segmentados, os objetos identificados são submetidos à etapa de extração de características, na qual são calculados descritores capazes de representar quantitativamente suas propriedades geométricas, morfológicas e estatísticas. Entre os descritores mais utilizados destacam-se a área projetada, o perímetro, o diâmetro equivalente, a razão de aspecto, a circularidade e parâmetros de textura. Esses atributos permitem a caracterização do tamanho e da forma dos cascalhos, bem como a análise da distribuição granulométrica e da variabilidade do material ao longo do tempo. Em sistemas com aquisição contínua de imagens, a análise temporal dessas características possibilita ainda a avaliação de tendências e mudanças no regime de geração e transporte dos sólidos (SONKA *et al.*, 2015).

Por fim, as características extraídas podem ser utilizadas em etapas de classificação ou regressão, dependendo do objetivo do sistema de visão computacional. Na classificação, os objetos ou conjuntos de partículas são associados a categorias previamente definidas, como


classes granulométricas ou tipos litológicos. Na regressão, busca-se estabelecer relações quantitativas entre os descritores visuais e variáveis contínuas de interesse. Essas etapas podem ser implementadas por meio de modelos estatísticos tradicionais ou algoritmos de aprendizado de máquina e redes neurais, permitindo a transformação dos dados visuais em informações diretamente aplicáveis ao monitoramento e à tomada de decisão operacional (GONZALEZ e WOODS, 2018).

A compreensão dessa sequência é essencial para o desenvolvimento de sistemas de visão computacional aplicados ao monitoramento de cascalhos em peneiras vibratórias, fornecendo a base conceitual necessária para a abordagem metodológica adotada neste estudo.

2.4 Redes neurais artificiais

A concepção das Redes Neurais Artificiais (RNAs) remonta a uma busca por mimetizar a capacidade de processamento de informação do cérebro humano. A trajetória de desenvolvimento dessa tecnologia é marcada por períodos de grande entusiasmo e subsequentes fases de ceticismo, refletindo os desafios teóricos e computacionais enfrentados ao longo de décadas. A compreensão dessa evolução é fundamental para contextualizar o estado da arte atual e as arquiteturas avançadas que dele derivam. A Figura 2.4 contextualiza a história da evolução das redes neurais e seus principais criadores, até a criação das redes neurais profundas.

Figura 2.4 – Contexto da evolução das redes neurais



Fonte: Adaptado de Ultralytics 2023.

A primeira formalização matemática de um neurônio artificial foi proposta em 1943 por Warren McCulloch, um neurofisiologista, e Walter Pitts, um matemático. O modelo de McCulloch-Pitts descrevia um neurônio como uma unidade de processamento simples que recebia múltiplos sinais de entrada binários e, com base em um limiar pré-definido, produzia uma única saída binária (MCCULLOCH e PITTS, 1943). Embora desprovido de um mecanismo de aprendizado, esse trabalho pioneiro estabeleceu que qualquer função lógica poderia, em teoria, ser computada por uma rede desses neurônios interconectados, lançando as bases conceituais para o campo da inteligência artificial (BISHOP, 2006).

O passo seguinte e decisivo na evolução das RNAs foi o desenvolvimento do Perceptron, por Frank Rosenblatt, em 1958. Diferentemente do modelo estático de McCulloch-Pitts, o Perceptron introduziu um mecanismo de aprendizado supervisionado. A arquitetura consistia em uma única camada de neurônios artificiais cujos pesos sinápticos eram ajustados iterativamente com base no erro entre a saída predita e a saída desejada (ROSENBLATT, 1958). Rosenblatt demonstrou que seu algoritmo de aprendizado era capaz de convergir para uma solução sempre que uma solução existisse para problemas linearmente separáveis. O Perceptron gerou grande otimismo, mas suas limitações foram expostas de forma contundente no livro “Perceptrons”, de Marvin Minsky e Seymour Papert (1969), que demonstrou matematicamente a incapacidade do modelo de resolver problemas não-lineares simples, como a função lógica XOR (OU exclusivo). Essa crítica contribuiu para uma drástica redução no financiamento e interesse em pesquisas na área, inaugurando o que ficou conhecido como o primeiro “inverno da IA” (MINSKY e PAPERT, 1969).

O renascimento do campo ocorreu em duas ondas principais. A primeira, na década de 1980, foi impulsionada pela popularização do algoritmo de retropropagação do erro (backpropagation). A segunda onda, que consolidou o que hoje conhecemos como Aprendizado Profundo, teve um marco em 2006 com o trabalho de Hinton e Salakhutdinov, que demonstrou que redes com múltiplas camadas ocultas possuem uma capacidade robusta de aprendizado de características e que a dificuldade de seu treinamento poderia ser mitigada por um método de inicialização camada por camada (HINTON e SALAKHUTDINOV, 2006; ZHAO *et al.*, 2024). Embora suas origens remontem a trabalhos anteriores, foi o artigo de David Rumelhart, Geoffrey Hinton e Ronald Williams, em 1986, que demonstrou sua eficácia no treinamento de redes neurais com múltiplas camadas, conhecidas como Perceptrons de Múltiplas Camadas (MLPs) (RUMELHART *et al.*, 1986). O algoritmo de backpropagation utiliza a regra da cadeia do cálculo diferencial para propagar o sinal de erro da camada de saída para as camadas internas, permitindo o ajuste dos pesos em toda a rede de forma a minimizar uma função de custo. Essa

capacidade de treinar redes profundas superou a principal limitação do Perceptron e abriu caminho para a solução de problemas complexos e não-lineares, reacendendo o interesse acadêmico e industrial pelas redes neurais.

2.4.1 Fundamentação Matemática

O funcionamento de uma rede neural artificial é sustentado por um conjunto de princípios matemáticos que definem desde a operação de um único neurônio até o processo de aprendizado de uma rede com milhões de parâmetros. A unidade fundamental de uma RNA é o neurônio artificial, um modelo matemático simplificado do neurônio biológico.

Um neurônio artificial recebe um vetor de entradas $x = [x_1, x_2, \dots, x_n]^T$ e calcula uma saída y . Cada entrada x_i é associada a um peso sináptico w_i , que representa a força da conexão. O neurônio soma ponderadamente todas as entradas e adiciona um termo de viés (*bias*) b , resultando no que se denomina entrada ponderada ou ativação z : (ROSENBLATT, 1958; GOODFELLOW *et al.*, 2016), de acordo com a Eq. 1.

$$z = \sum w_i x_i + b \quad (\text{Equação 1})$$

O valor de z é então passado por uma função de ativação não-linear, $\sigma(z)$, que produz a saída final do neurônio, $y = \sigma(z)$. A não-linearidade introduzida pela função de ativação é crucial, pois permite que a rede aprenda representações complexas e modele relações não-lineares presentes nos dados (GOODFELLOW *et al.*, 2016).

Existem diversas funções de ativação, cada uma com características específicas. As mais tradicionais incluem:

Função Sigmoid: $\sigma(z) = \frac{1}{1+e^{-z}}$. Comprime a saída para o intervalo $(0, 1)$, sendo historicamente utilizada em camadas de saída para problemas de classificação binária. No entanto, sofre do problema de saturação e desaparecimento do gradiente (*vanishing gradient*) em redes profundas.

Função Tangente Hiperbólica ($\tanh$): $\sigma(z) = \frac{(e^z - e^{-z})}{(e^z + e^{-z})}$. Similar à sigmoide, mas comprime a saída para o intervalo $(-1, 1)$. É centrada em zero, o que pode acelerar a convergência, mas também sofre de saturação.

Função Unidade Linear Retificada (ReLU): $\sigma(z) = \max(0, z)$. Tornou-se a função de ativação padrão em redes profundas modernas. É computacionalmente eficiente e não satura para valores positivos, mitigando o problema do desaparecimento do gradiente. Variações como Leaky ReLU e Parametric ReLU foram propostas para lidar com o problema do “neurônio morto” (quando a saída é sempre zero para entradas negativas) (GLOROT e BENGIO, 2010; GOODFELLOW *et al.*, 2016).

O processo de aprendizado de uma RNA consiste em encontrar o conjunto de pesos w e vieses b que minimiza a discrepância entre as previsões da rede e os valores reais. Essa discrepância é quantificada por uma função de custo (ou função de perda, *loss function*). A escolha da função de custo depende da natureza da tarefa. Para problemas de regressão, o Erro Quadrático Médio (MSE) é comumente utilizado. Para problemas de classificação, a Entropia Cruzada Categórica (*Categorical Cross-Entropy*) é a mais indicada (GOODFELLOW *et al.*, 2016).

O algoritmo do gradiente descendente (*Gradient Descent*) é o método de otimização mais fundamental para minimizar a função de perda. A ideia é ajustar iterativamente os parâmetros da rede na direção oposta ao gradiente da função de custo em relação a esses parâmetros. A regra de atualização para um peso genérico w_{ij} é dada pela (Equação 2:

$$w_{ij} = w_{ij} - \eta \frac{\partial C}{\partial w_{ij}} \quad (\text{Equação 2})$$

onde η é a taxa de aprendizado (*learning rate*), um hiperparâmetro que controla o tamanho do passo em cada iteração. O cálculo desses gradientes parciais $\partial C / \partial w_{ij}$ em redes profundas é realizado de forma eficiente pelo algoritmo de *backpropagation*, que aplica sistematicamente a regra da cadeia para computar os gradientes camada por camada, da saída para a entrada (RUMELHART *et al.*, 1986).

2.4.2 Aplicações na Indústria

As Redes Neurais Artificiais e, mais amplamente, o Aprendizado Profundo (*Deep Learning*), transcenderam o ambiente acadêmico e se tornaram ferramentas transformadoras em diversas áreas da indústria. A capacidade desses modelos de aprender padrões complexos a partir de grandes volumes de dados (*Big Data*) viabilizou soluções para problemas antes

considerados intratáveis por métodos de programação tradicionais ou técnicas de machine learning clássicas.

No setor de manufatura, as RNA são amplamente empregadas em sistemas de controle de qualidade automatizado. Utilizando dados de sensores visuais (câmeras), sistemas baseados em redes neurais podem inspecionar produtos em tempo real na linha de produção, detectando defeitos superficiais, erros de montagem ou anomalias dimensionais com precisão e velocidade superior à inspeção humana. Essa aplicação reduz custos associados a falhas de qualidade, aumenta a eficiência da produção e garante a conformidade dos produtos com especificações rigorosas (WEIMER *et al.*, 2016).

Outra aplicação de grande impacto é a manutenção preditiva. Modelos de RNA podem analisar dados de sensores instalados em equipamentos industriais (vibração, temperatura, pressão, acústica) para identificar padrões sutis que antecedem uma falha. Ao prever falhas iminentes, as empresas podem agendar intervenções de manutenção de forma proativa, evitando paradas não planejadas, reduzindo custos de reparo e prolongando a vida útil dos ativos. Essa abordagem representa uma evolução significativa em relação às estratégias de manutenção corretiva (após a falha) e preventiva (baseada em cronogramas fixos) (KHAN e YAIRI, 2018).

Na otimização de processos, as redes neurais são utilizadas para modelar relações complexas entre variáveis de processo e indicadores de desempenho (KPIs), como consumo de energia, rendimento do produto ou emissão de poluentes. Uma vez treinado, o modelo neural pode atuar como um “gêmeo digital” (*digital twin*) do processo, permitindo a simulação de diferentes cenários operacionais e a identificação dos parâmetros que otimizam a performance. Esses modelos podem ser integrados a sistemas de controle avançado (APC) para ajustar as condições de operação em tempo real, garantindo que o processo opere sempre em seu ponto ótimo (NCSIZ e YILDIRIM, 2004).

No contexto da indústria de petróleo e gás, foco desta dissertação, as RNAs têm sido exploradas para análise de dados sísmicos, otimização de perfuração, previsão de produção de poços e, como será detalhado no capítulo seguinte, na análise de imagens para monitoramento de processos, como o de controle de sólidos em peneiras vibratórias. A capacidade de extrair informações valiosas de dados não estruturados, como imagens e vídeos, é uma das principais forças motrizes para a adoção dessas tecnologias no setor.

2.4.3 Redes neurais convolucionais e arquiteturas modernas

As Redes Neurais Convolucionais (*Convolutional Neural Networks*, ou CNNs) representam uma classe especializada de redes neurais projetada especificamente para processar dados que possuem uma topologia de grade, como as imagens. Diferentemente dos Perceptrons de Múltiplas Camadas (MLPs), que tratam os dados de entrada como um vetor unidimensional e, portanto, perdem a informação espacial, as CNNs são capazes de preservar e explorar as relações espaciais entre os pixels. Essa característica é fundamental para tarefas de visão computacional, como reconhecimento de objetos, segmentação e classificação de imagens (GOODFELLOW *et al.*, 2016).

A principal inovação das CNNs é a camada convolucional. Em vez de conectar cada neurônio de uma camada a todos os neurônios da camada anterior, a camada convolucional utiliza um conjunto de filtros (ou *kernels*) de tamanho reduzido (e.g., 3x3 ou 5x5). Cada filtro desliza sobre a imagem de entrada, realizando uma operação de convolução em cada posição. Essa operação consiste em um produto escalar entre os valores do filtro e a porção correspondente da imagem, gerando um mapa de características (*feature map*). Cada filtro aprende a detectar um padrão específico, como bordas, texturas ou formas simples. A utilização de múltiplos filtros permite que a rede aprenda a reconhecer uma variedade de características hierárquicas, das mais simples nas camadas iniciais às mais complexas nas camadas profundas (LECUN *et al.*, 2015). Dois parâmetros importantes governam essa operação: o *stride*, que define o passo do deslizamento do filtro, e o *padding*, que consiste em adicionar pixels (geralmente com valor zero) às bordas da imagem para controlar a dimensão espacial da saída e garantir que as informações nas bordas não sejam perdidas (ZHAO *et al.*, 2024).

Essa abordagem, inspirada no mecanismo de campo receptivo da biologia, confere às CNNs propriedades fundamentais como conectividade local, compartilhamento de parâmetros e a capacidade de realizar subamostragem, tornando-as extremamente eficientes para o aprendizado de características hierárquicas (LI *et al.*, 2021; ZHAO *et al.*, 2024). A esparsidade decorre do fato de que cada neurônio no mapa de características está conectado apenas a uma pequena região da entrada (o campo receptivo). O compartilhamento de parâmetros significa que o mesmo filtro é utilizado em toda a imagem, reduzindo drasticamente o número total de parâmetros a serem aprendidos e tornando o modelo mais eficiente e menos propenso a sobreajuste (*overfitting*) (GOODFELLOW *et al.*, 2016).

Após a camada convolucional, é comum a aplicação de uma camada de pooling (agrupamento). A função dessa camada é reduzir progressivamente a dimensão espacial

(largura e altura) dos mapas de características, o que diminui a complexidade computacional e o número de parâmetros, além de conferir ao modelo um certo grau de invariância a pequenas translações no objeto de interesse. As duas estratégias mais comuns são o *Max Pooling*, que seleciona o valor máximo de uma vizinhança, e o *Average Pooling*, que calcula a média. Ao fazer isso, a camada de *pooling* também confere à rede um grau de invariância a pequenas translações no objeto (BHATT *et al.*, 2021; ZHAO *et al.*, 2024). A operação de *pooling* mais comum é o *Max Pooling*, que extrai o valor máximo de uma pequena janela (e.g., 2x2) que desliza sobre o mapa de características (KRIZHEVSKY *et al.*, 2012). A Normalização em Lote (*Batch Normalization*) estabiliza e acelera o treinamento ao normalizar a saída de uma camada anterior para ter média zero e variância unitária (IOFFE e SZEGEDY, 2015).

Uma arquitetura de CNN típica é composta por uma sequência de camadas e componentes fundamentais que operam em conjunto para extrair características e realizar a classificação. A seguir, detalham-se outros componentes importantes nas redes neurais profundas, de acordo com Zhao *et al.* (2024).

Função de Ativação: Para que a rede possa aprender padrões complexos e não-lineares, uma função de ativação é aplicada após as operações de convolução. Enquanto funções como a Sigmoid e a Tangente Hiperbólica (Tanh) foram historicamente utilizadas, a Unidade Linear Retificada (ReLU) tornou-se o padrão na maioria das arquiteturas modernas por sua simplicidade e eficácia em mitigar o problema do desaparecimento do gradiente (*vanishing gradient*). Variações como a Leaky ReLU foram propostas para solucionar o problema do “neurônio morto” (*Dead ReLU*), que pode ocorrer quando as entradas para a função ReLU são negativas (NWANKPA *et al.*, 2018; ZHAO *et al.*, 2024).

Técnicas de Regularização: Para melhorar a capacidade de generalização do modelo e evitar o sobreajuste, a principal técnica utilizada é o *Dropout*, em que é desativado aleatoriamente uma fração dos neurônios durante o treinamento, forçando a rede a aprender representações mais robustas e menos dependentes de neurônios específicos (SRIVASTAVA *et al.*, 2014).

Camada Totalmente Conectada (Fully Connected Layer): Na fase final da arquitetura, os mapas de características de alto nível, já processados, são “achatados” em um vetor e alimentados em uma ou mais camadas totalmente conectadas. Estas camadas, que funcionam de maneira idêntica a um Perceptron de Múltiplas Camadas, integram as características locais aprendidas e realizam a tarefa final de classificação, atribuindo uma probabilidade para cada classe de saída (SAINATH *et al.*, 2013; ZHAO *et al.*, 2024).

Um exemplo que ilustra essa arquitetura é a rede LeNet-5, desenvolvida por Yann LeCun e seus colaboradores em 1998 para o reconhecimento de dígitos manuscritos (LECUN *et al.*, 1998). A LeNet-5 foi pioneira ao consolidar os blocos de convolução e pooling, alcançando mais de 98% de acurácia no banco de dados MNIST e servindo de base para arquiteturas futuras (ZHAO *et al.*, 2024). O verdadeiro ponto de inflexão para as CNNs ocorreu em 2012, quando a arquitetura AlexNet venceu a competição ImageNet Large Scale Visual Recognition Competition (ILSVRC) com uma margem de erro significativamente menor que a dos concorrentes (KRIZHEVSKY *et al.*, 2012). A AlexNet, mais profunda e complexa que a LeNet, foi a primeira a utilizar a função de ativação ReLU e técnicas como Dropout, estabelecendo um novo paradigma. A partir dela, uma sucessão de arquiteturas cada vez mais profundas e eficientes foram propostas, como a VGG, GoogLeNet e a ResNet, que introduziu as conexões residuais para permitir o treinamento de redes com centenas de camadas (ZHAO *et al.*, 2024). A LeNet-5, embora simples para os padrões atuais, continha todos os componentes fundamentais de uma CNN moderna e demonstrou um desempenho notável para a época, consolidando a eficácia da abordagem convolucional e servindo de base para o desenvolvimento de arquiteturas muito mais profundas e complexas nas décadas seguintes.

Os modelos híbridos consistem na integração entre modelos fundamentados em princípios físicos e relações fenomenológicas, e técnicas orientadas por dados, como redes neurais artificiais e algoritmos de aprendizado de máquina. Essa combinação permite representar sistemas complexos de forma mais realista, preservando coerência física ao mesmo tempo em que captura comportamentos não lineares e variabilidades difíceis de descrever apenas por equações determinísticas. Em aplicações industriais, essa abordagem tem sido utilizada para aumentar a precisão preditiva, melhorar estratégias de controle e apoiar sistemas avançados de monitoramento em tempo real (ZHANG *et al.*, 2026)

2.4.3.1 U-Net: Segmentação Semântica

No contexto da visão computacional, a segmentação semântica é a tarefa de classificar cada pixel de uma imagem a uma determinada classe de objeto. Diferentemente da classificação de imagens (que atribui um único rótulo à imagem inteira) ou da detecção de objetos (que delimita objetos com caixas retangulares), a segmentação fornece uma compreensão muito mais detalhada da cena, gerando um mapa de segmentação com a mesma resolução da imagem de entrada. Essa tarefa é particularmente relevante em domínios como imagens médicas, veículos autônomos e, no escopo deste trabalho, na análise de materiais particulados.

A U-Net é uma arquitetura de rede neural convolucional desenvolvida especificamente para a segmentação semântica, proposta por Ronneberger *et al.*, 2015. Sua principal aplicação original foi na segmentação de imagens biomédicas, onde frequentemente se dispõe de um número limitado de amostras para treinamento, mas se exige uma localização muito precisa das fronteiras dos objetos.


A arquitetura da U-Net, ilustrada na Figura 2.5, é caracterizada por seu formato em “U”, que lhe confere o nome. Ela consiste em duas partes principais: um caminho de contração (*encoder*) e um caminho de expansão (*decoder*).

Encoder (Caminho de Contração): Esta parte segue a arquitetura típica de uma CNN. É composta por uma sequência de blocos, cada um contendo duas camadas de convolução 3x3 (com ativação ReLU) seguidas por uma operação de Max Pooling 2x2. A cada bloco, a resolução espacial da imagem é reduzida pela metade, enquanto o número de canais de características é dobrado. O objetivo do *encoder* é capturar o contexto da imagem, extraindo características hierárquicas em diferentes escalas.

Decoder (Caminho de Expansão): Esta parte é responsável por reconstruir o mapa de segmentação na resolução original. A cada etapa do *decoder*, o mapa de características da etapa anterior passa por uma “*up-convolution*” (ou convolução transposta) 2x2, que aumenta a resolução espacial e reduz o número de canais. A inovação crucial da U-Net reside nas conexões de salto (*skip connections*).

As conexões de salto concatenam os mapas de características do caminho de contração com os mapas de características correspondentes (de mesma resolução) no caminho de expansão. Essa fusão permite que o *decoder* utilize diretamente as informações de localização de alta resolução perdidas durante a contração, combinando-as com as informações contextuais de alto nível aprendidas nas camadas mais profundas. O resultado é uma localização muito mais precisa das bordas dos objetos segmentados, que é uma das principais vantagens da U-Net (RONNEBERGER *et al.*, 2015). Ao final do caminho de expansão, uma convolução 1x1 é utilizada para mapear os canais de características finais para o número desejado de classes de segmentação, como pode ser visto na Figura 2.5.

Figura 2.5 - Arquitetura da rede U-Net.



Fonte: Adaptado de Ronneberger *et al.*, 2015.

Para o presente trabalho, a U-Net é particularmente adequada, pois a tarefa de estimar a área preenchida por cascalhos na peneira pode ser formulada como um problema de segmentação semântica, onde o objetivo é classificar cada pixel como cascalho ou fundo. A capacidade da U-Net de produzir segmentações precisas com um conjunto de dados relativamente modesto a torna uma escolha promissora.

2.4.3.2 YOLOv8: Detecção de Objetos em Tempo Real

Enquanto a U-Net se especializa em fornecer uma segmentação densa e precisa, outras aplicações demandam a identificação e localização rápida de múltiplos objetos em uma cena. A detecção de objetos é a tarefa de localizar instâncias de objetos de certas classes e delimitá-las com caixas retangulares (*bounding boxes*). Para aplicações em tempo real, como o monitoramento contínuo de um processo industrial, a velocidade de inferência do modelo é um requisito crítico.


A família de modelos YOLO (*You Only Look Once*) revolucionou a área de detecção de objetos ao propor uma abordagem que reformula a tarefa como um único problema de regressão. Versões subsequentes, como YOLOv2 e YOLOv3, introduziram melhorias como o uso de *batch normalization*, um *backbone* mais robusto (*DarkNet*) e a detecção em múltiplas escalas para identificar objetos de diferentes tamanhos com maior eficácia. Em vez de utilizar pipelines complexos de múltiplas etapas, os modelos YOLO processam a imagem inteira de uma só vez, predizendo simultaneamente as caixas delimitadoras e as probabilidades de classe

para todos os objetos. Essa filosofia de projeto resulta em velocidades de inferência extremamente altas, tornando-os ideais para aplicações em tempo real. (REDMON *et al.*, 2016).

O YOLOv8, lançado pela Ultralytics em janeiro de 2023, é a mais recente iteração dessa família de modelos, representando um redesenho significativo em relação às versões anteriores e estabelecendo um novo estado da arte em termos de equilíbrio entre precisão e velocidade (JOCHER *et al.*, 2023). A arquitetura do YOLOv8, esquematizada na

Figura 2.6, mantém a filosofia geral do YOLO, mas introduz várias inovações importantes.

Figura 2.6 - Arquitetura simplificada do modelo YOLOv8



Fonte: Adaptado de Laganier *et al.*, 2025.

A arquitetura do YOLOv8 pode ser dividida em três componentes principais:

- Backbone:** Responsável pela extração de características da imagem de entrada. O YOLOv8 utiliza um *backbone* moderno e eficiente, inspirado em arquiteturas como a CSPNet (*Cross Stage Partial Network*), que otimiza o fluxo de gradientes e reduz a complexidade computacional. O *backbone* processa a imagem em diferentes estágios, gerando mapas de características em múltiplas escalas.
- Neck:** Este componente atua como uma ponte entre o *backbone* e a cabeça de detecção. Sua função é agregar e combinar os mapas de características de diferentes escalas provenientes do *backbone*. O YOLOv8 emprega mecanismos como o FPN (*Feature Pyramid Network*) e o PAN (*Path Aggregation Network*) para fundir informações de baixo nível (com alta resolução espacial) e de alto nível (com alta riqueza semântica), permitindo que o modelo detecte objetos de diferentes tamanhos com maior eficácia.
- Head (Cabeça de Detecção):** A principal inovação do YOLOv8 reside em sua cabeça de detecção, que é desacoplada e livre de âncoras (*anchor-free*). Em modelos anteriores, a

cabeça de detecção predizia simultaneamente a classe e as coordenadas da caixa. No YOLOv8, essas tarefas são separadas (desacopladas), o que melhora a convergência e o desempenho. Além disso, a abordagem *anchor-free* elimina a necessidade de caixas de âncora pré-definidas, um conjunto de hiperparâmetros que precisava ser cuidadosamente ajustado para cada conjunto de dados. Em vez disso, o modelo prevê diretamente o centro do objeto e suas dimensões, simplificando o processo de treinamento e melhorando a capacidade de generalização (JOCHER *et al.*, 2023).

Essa rede convolucional não se limita à detecção de objetos. A Ultralytics disponibiliza variantes pré-treinadas para diferentes tarefas, incluindo segmentação de instâncias (YOLOv8-seg) e classificação de imagens (YOLOv8-cls). Essa versatilidade, combinada com seu alto desempenho e facilidade de uso, o torna uma ferramenta poderosa para o desenvolvimento de sistemas de visão computacional. No contexto desta dissertação, o YOLOv8 é utilizado tanto para a detecção dos cascalhos quanto para a segmentação.

2.5 Estado da arte de trabalhos na área de visão computacional

A aplicação de técnicas de processamento de imagens e visão computacional para a análise de cascalhos de perfuração tem sido progressivamente explorada como alternativa aos métodos convencionais, que são majoritariamente manuais e dependentes de interpretação subjetiva. Os primeiros trabalhos concentram-se na quantificação indireta de sólidos sobre peneiras vibratórias, com foco no monitoramento do desempenho do sistema de separação. Nesse contexto, Marana *et al.* (2009) desenvolveram uma metodologia baseada na aquisição de imagens da superfície das telas de peneiras vibratórias, seguida de etapas de pré-processamento, como filtragem e extração de características de textura e ocupação superficial. As imagens foram analisadas por classificadores supervisionados, incluindo florestas de caminhos ótimos, redes neurais artificiais, máquinas de vetores de suporte e classificadores bayesianos. Os autores reportaram valores superiores a 85 % na estimativa do volume global de sólidos sobre a tela da peneira, demonstrando o potencial da visão computacional para monitoramento do processo. Entretanto, o método não realizava a detecção individual dos cascalhos, limitando-se a métricas globais de ocupação superficial dos sólidos.

Avançando nessa linha, Serapião *et al.* (2011) propuseram a detecção direta de cascalhos em um protótipo experimental de peneira vibratória instrumentada com sistema de aquisição de imagens. A metodologia envolveu normalização de iluminação, filtragem espacial e segmentação das imagens antes da aplicação do algoritmo de detecção. Os resultados

indicaram melhoria significativa na identificação visual das partículas após o pré-processamento, com taxas de detecção superiores a 70 % em condições controladas. Contudo, o estudo não apresentou uma análise estatística aprofundada dos erros nem validação em escala industrial, limitando a generalização dos resultados.

Posteriormente, Matta *et al.* (2014) destacaram a complexidade intrínseca da análise de imagens em peneiras vibratórias, enfatizando a necessidade de delimitação rigorosa da região de interesse. Utilizando imagens obtidas em um sistema piloto, os autores demonstraram que a ausência de recorte adequado da área analisada resultava em desvios superiores a 30 % nos parâmetros estimados. Com a definição apropriada da região de interesse, os desvios foram reduzidos para valores inferiores a 10 %, evidenciando que a confiabilidade das análises depende fortemente do controle geométrico e visual do sistema.

Além da quantificação de sólidos, técnicas de visão computacional passaram a ser aplicadas à identificação de formações geológicas a partir de imagens de cascalhos. Khojasteh *et al.* (2015) utilizaram imagens digitais associadas à extração de características de textura, cor e morfologia, empregando máquinas de vetores de suporte para classificação litológica. Os resultados indicaram taxas de acerto entre 80 % e 90 % na identificação automatizada das formações geológicas avaliadas, demonstrando que imagens de cascalhos contêm informações relevantes para inferência geológica. Entretanto, o desempenho do modelo mostrou-se fortemente dependente da qualidade da base de treinamento e das condições de aquisição das imagens.

Em estudos voltados à eficiência operacional, Silva (2017) e Barbosa (2018) integraram técnicas de processamento de imagens à análise de variáveis operacionais de peneiras vibratórias, como vazão, inclinação e intensidade de vibração. As imagens foram utilizadas para quantificar a distribuição superficial de sólidos e correlacioná-la com a eficiência do peneiramento. Os autores observaram variações de até 25 % na eficiência de separação associadas a mudanças operacionais, sendo que as métricas visuais apresentaram boa correlação com os parâmetros tradicionais do processo. Ainda assim, a visão computacional foi empregada como ferramenta complementar, e não como método principal de controle.

Han *et al.* (2018) estabeleceram as bases para a análise quantitativa em 3D. Os autores desenvolveram e testaram um protótipo que combinava uma câmera 2D com um scanner laser de perfil 3D. Em testes de laboratório controlados, o sistema demonstrou capacidade de medir o volume de detritos e caracterizar a forma de desmoronamentos artificiais e naturais com precisão. A validação em campo, realizada em uma instalação com peneira vibratória real, confirmou a robustez do sistema. Os resultados mostraram que ele permanecia funcional e

preciso mesmo sob variações desafiadoras de iluminação, poeira, umidade e a presença de fluido de perfuração cobrindo as amostras. Um resultado particularmente relevante foi a capacidade do algoritmo de distinguir entre cascalhos regulares e irregulares, com base em características geométricas extraídas da nuvem de pontos 3D, como angularidade e planicidade. Isso indica que a técnica desenvolvida permite identificar anomalias no perfil de cascalhos, induzindo a identificação de cascalhos não desejáveis como os de desmoronamentos.

Grossi (2020), aprofundou a análise ao investigar o escoamento de materiais particulados em peneiras vibratórias operando em via seca e via úmida. A metodologia baseou-se na aquisição de imagens durante a operação e na análise dos padrões de escoamento das partículas. Os resultados mostraram diferenças significativas entre os regimes, com aumento da instabilidade visual e maior dificuldade de segmentação das partículas no regime úmido, devido à presença de fluido aderido aos cascalhos. Foram identificadas correlações entre padrões visuais e instabilidades operacionais, com variações superiores a 20 % nos parâmetros estimados entre os dois regimes.

Na temática do avanço da inteligência artificial, Badis *et al.* (2021) implementaram um sistema que utiliza redes neurais convolucionais para analisar imagens de cascalhos capturadas por uma câmera instalada na peneira vibratória. Os resultados reportados são expressivos: o modelo de IA atingiu um nível de confiança notavelmente alto na identificação e classificação do tipo, forma e tamanho dos cascalhos individuais. Este desempenho permitiu que o sistema gerasse alertas precoces para condições anormais, como a presença de cascalhos grandes ou desmoronamentos que indicavam potencial instabilidade do poço ou zonas de pressão anormal. A principal conquista foi demonstrar, com dados concretos, que a visão computacional acoplada a modelos de *machine learning* poderia superar a subjetividade e a intermitência da análise humana, oferecendo uma detecção contínua e objetiva.

Em um estudo mais recente, Grossi *et. al* (2023), apresentou metodologias mais robustas de visão computacional aplicadas ao monitoramento de cascalhos em sistemas de tratamento de fluidos de perfuração, integrando processamento de imagens, análise estatística e interpretação operacional. Os resultados indicaram redução significativa da variabilidade dos dados, com erros inferiores a 10 % em condições próximas às industriais, evidenciando a maturidade crescente das técnicas propostas como potencial ferramenta para teste em maior escala.

A transição das abordagens experimentais e teórico-computacionais para aplicações em campo é evidenciada em literatura para os seguintes trabalhos:

Em 2024, Ruggiero *et al.* representou um sistema baseado em câmeras de alta resolução e à prova de explosão, testando e validado em três poços reais, em diferentes países e locais. Os resultados práticos foram abrangentes: o sistema provou ser capaz de realizar a detecção e quantificação em tempo real de cascalhos, desmoronamentos, objetos estranhos, o nível da lama na tela, transbordamentos e danos às telas da peneira. O sucesso da implantação resultou em dois ganhos tangíveis principais: primeiro, uma redução substancial da necessidade de presença humana na zona perigosa da peneira, com a equipe sendo alertada a se deslocar apenas quando necessário; segundo, a geração de um fluxo contínuo de dados objetivos e de alta frequência que pode ser correlacionado com outros parâmetros de perfuração, proporcionando uma visão integrada da condição do poço.

Montes *et al.* (2024) propuseram um método automatizado para a caracterização, em tempo real, de cascalhos retornados durante operações de perfuração, com foco na avaliação da limpeza e da estabilidade do poço. O sistema desenvolvido integra imagens de alta resolução e dados tridimensionais obtidos por um sensor a laser, permitindo estimar volume, distribuição granulométrica e características morfológicas das partículas, mesmo em condições desafiadoras, como presença de fluido de perfuração, empilhamento de sólidos e baixo contraste visual. Os autores combinaram técnicas de pré-processamento de imagens, redes neurais convolucionais profundas (VGG-16, Mask R-CNN e FPN), segmentação semântica/panóptica e ajuste elíptico para extração de parâmetros geométricos, alcançando erros inferiores a 10% na estimativa volumétrica e elevadas taxas de detecção/classificação de cascalhos. Como principal contribuição, o estudo demonstra o potencial de sistemas inteligentes de sensoriamento para substituir inspeções manuais subjetivas e tardias, fornecendo suporte operacional contínuo para prevenção de eventos não produtivos.

No mesmo ano, Wang *et al.* (2024) direcionaram a inovação para o controle ativo e em malha fechada para um sistema inteligente que não apenas monitora, mas também atua. Utilizando um par de câmeras industriais e algoritmos de processamento de imagem (como correção de perspectiva, segmentação por limiar local e análise morfológica), o sistema identifica o estado da separação sólido-líquido na tela. O resultado quantificado desse processamento foi uma precisão média de 93,64% na identificação da língua de fluido, métrica crítica para o controle e eficiência da separação sólido-líquido. Com base nessa análise, o sistema comanda motores servo que ajustam automaticamente o ângulo de inclinação da tela da peneira. Os experimentos validaram que esse controle automatizado e em tempo real consegue otimizar dinamicamente a eficiência do peneiramento, respondendo proativamente a

anomalias na superfície da tela que, no método manual, levariam mais tempo para ser corrigidas.

O trabalho de Gosavi et. al (2024), apresenta um avanço metodológico crucial ao desenvolver e validar um sistema autônomo de monitoramento por imagem especificamente projetado para medir a taxa de recuperação de cascalhos em tempo real, um parâmetro direto para avaliar a eficiência da limpeza do poço. Diferente de abordagens que focam apenas na detecção, este estudo buscou uma quantificação absoluta e relativa do volume de cascalhos recuperado. Para isso, os autores implementaram um sistema de sensor óptico com software de análise de imagem embarcado, instalado na zona de risco próximo à peneira vibratória, monitorando continuamente seções de poço lateral de 6,75 polegadas.

A robustez do modelo foi assegurada por uma validação em duas etapas. Primeiramente, em ambiente controlado, o modelo de análise de imagem foi calibrado e verificado contra um modelo de transporte de cascalhos experimentalmente validado, utilizando um circuito de circulação de pesquisa com diferentes taxas de carga, volumes e tipos de fluido. Em seguida, o sistema foi implantado em campo para o monitoramento contínuo de cinco poços. Os resultados operacionais foram concretos e mensuráveis. O sistema analisou opticamente aproximadamente 500 barris de cascalhos perfurados, comparando-os com volumes esperados. A carga relativa de cascalhos mostrou uma correlação credível com períodos controlados de baixa ROP (*Rate of Penetration*) e de circulação. A taxa real de recuperação de cascalhos (em barris por hora) apresentou resultados lógicos durante períodos de luz diurna, validando a precisão da abordagem. O estudo também gerou informações valiosas sobre o desempenho do sistema em condições de baixa luminosidade, a distinção entre condições sólidos molhados versus secos na peneira, e o potencial de economia de tempo com base nas cargas medidas.

De forma complementar e ainda mais recente, Svendsen *et al.* (2025) conduziram uma validação abrangente de um sistema de visão computacional em condições operacionais extensivas e de longa duração. O sistema, composto por câmeras com software embarcado instaladas na zona de risco acima das peneiras vibratórias, foi implantado e monitorado remotamente em cinco poços consecutivos no Setor Offshore Norueguês, abrangendo um período de oito meses e diâmetros de poço de 16½ a 8½ polegadas. Os resultados alcançados foram robustos e mensuráveis. Primeiramente, o modelo de visão computacional foi calibrado e validado através de um método rigoroso: amostras de rocha de tamanho conhecido foram inseridas no fluxo de cascalhos, e a distribuição de tamanho de cascalhos foi medida fisicamente

em amostras e comparada com as leituras do sistema. Esse processo permitiu calibrar um modelo que media com precisão cascalhos na faixa de 10 mm a 45 mm.

Um dos resultados mais significativos foi a detecção bem-sucedida de desmoronamentos (*cavings*). Os autores introduziram pragmaticamente o termo “*Unidentified Falling Object*” (UFO) para classificar objetos anormalmente grandes detectados, que serviam como indicadores potenciais de desmoronamentos. O sistema demonstrou uma correlação credível com mudanças na formação do poço, alertando a equipe de perfuração em quase tempo real sobre questões suspeitas. Além do objetivo principal, o sistema provou sua versatilidade ao fazer observações valiosas sobre transbordamento de cascalhos (*cuttings overflow*), desempenho da vibração da peneira vibratória e potencial para economia de tempo em atividades de limpeza do poço.

De forma geral, observa-se que as evoluções das metodologias reportadas em literatura acompanham a transição e a necessidade de sistemas automatizados capazes de realizar detecção individual de partículas, inferência geológica, medição da vazão de cascalhos e monitoramento em tempo real de forma eficiente. Contudo, apesar dos avanços quantitativos reportados, persistem desafios relacionados à robustez dos algoritmos frente às variações operacionais, à padronização da aquisição de imagens e à integração entre modelos visuais e fenômenos físico-operacionais de problemas reais, como exemplo os cascalhos oriundos processo de perfuração em ambientes reais.

Ainda, destaca-se a lacuna de técnicas acopladas aos sistemas de visão computacionais como estratégias de aprimoramento e redirecionamento de problemas operacionais, fator que está diretamente relacionado com a eficiência final dos algoritmos desenvolvidos. A integração de ferramentas que auxiliem nas etapas de análise, classificação e identificação das imagens pode ser grande aliada dos sistemas baseados em visão computacional, representando uma oportunidade clara para o desenvolvimento, otimização e validação de soluções integradas que possam ser acopladas ou implementadas em sistemas de monitoramento de cascalhos existentes.

2.6 Avaliação crítica e limitações das abordagens existentes

A revisão bibliográfica apresentada evidencia um esforço contínuo da comunidade científica e da indústria em automatizar a análise de cascalhos de perfuração. No entanto, ao confrontar as metodologias clássicas de processamento digital de imagens com os requisitos de

robustez exigidos pelo ambiente de sonda, emergem limitações operacionais severas que ainda não foram plenamente superadas.

As principais barreiras residem na sensibilidade ambiental e na baixa capacidade de generalização dos algoritmos tradicionais. Enquanto técnicas baseadas em limiarização e extração de características morfológicas operam satisfatoriamente em ambientes laboratoriais controlados, sua performance degrada drasticamente em campo devido a vibrações mecânicas intensas, variações bruscas de iluminação e a presença de fluidos de perfuração com diferentes níveis de opacidade. Além disso, a dependência de um ajuste manual exaustivo de parâmetros para cada nova condição de operação torna esses sistemas pouco práticos para a escala industrial.

Diante desse cenário, a transição para arquiteturas de aprendizado profundo (*Deep Learning*), embora promissora, também introduz novos desafios, como a necessidade de banco de dados massivos e rotulagem precisa, além da alta demanda computacional para inferência em tempo real. Diante desse cenário, a metodologia de rotulagem do objeto de interesse apresentado e criação do banco de dados apresentado nesse trabalho, contribuem e otimizam essa etapa, muitas vezes considerada uma etapa lenta, além de aplicar o software de detecção utilizando duas arquiteturas, e, buscando equilibrar a precisão da segmentação semântica na U-Net e a velocidade de detecção na YOLOv8n, necessárias para o monitoramento contínuo das peneiras vibratórias. A implementação de uma interface gráfica para apoio ao operador integrando os dados obtidos através da câmera de monitoramento e técnicas de visão computacional para a estimativa da Área Preenchida e Velocidade de escoamento também representa um avanço para aplicação e validação do software em uma operação em tempo real.

CAPÍTULO 3. METODOLOGIA

Resumo


Neste capítulo, descreve-se detalhadamente a abordagem metodológica híbrida adotada, dividida em etapas experimentais e computacionais, para o desenvolvimento do sistema de monitoramento. A metodologia experimental detalha os ensaios realizados em uma peneira vibratória industrial M-I SWACO em escala piloto, utilizando uma suspensão sintética composta por água, argila e areia para simular fluidos de perfuração reais. São especificadas as condições operacionais variáveis, incluindo rotações de 1200 e 1800 RPM e vazões de 20, 30 e 40 m³/h, bem como o sistema de aquisição de vídeos em alta resolução. A metodologia computacional descreve o processo de construção e curadoria do banco de dados, destacando o uso inovador da ferramenta Roboflow e do modelo *Segment Anything Model 2* (SAM 2) para a rotulagem assistida e geração de máscaras binárias precisas (*ground truth*). Explica-se a aplicação de técnicas de aumento de dados (*data augmentation*) para expandir o conjunto amostral e evitar sobreajuste (*overfitting*). São detalhados os procedimentos de treinamento e otimização de hiperparâmetros para as redes neurais U-Net (em ambiente MATLAB) e YOLOv8 (em ambiente Python). Por fim, apresenta-se o equacionamento matemático desenvolvido para a estimativa dos parâmetros operacionais de interesse, definindo as fórmulas para o cálculo da porcentagem de área preenchida e o rastreamento de deslocamento de centroides visando a determinação da velocidade média de escoamento.

Palavras-chave: visão computacional; rotulagem automática; U-Net; YOLOv8

3.1 Visão geral da metodologia

A metodologia adotada neste trabalho foi estruturada em duas etapas principais: experimental e computacional, conforme ilustrado no fluxograma apresentado na Figura 3.1. A etapa experimental teve como objetivo a geração controlada de dados reais a partir da operação de uma peneira vibratória industrial, enquanto a etapa computacional foi dedicada ao desenvolvimento de um sistema de visão computacional para análise automática das imagens adquiridas, incluindo segmentação, extração de parâmetros operacionais e monitoramento do processo.

Figura 3.1 - Fluxograma do Software de Visão Computacional.



Fonte: Elaborada pelo autor.

Essa abordagem integrada permitiu associar condições operacionais conhecidas a resultados quantitativos obtidos por técnicas de processamento de imagens e aprendizado profundo, viabilizando a avaliação do desempenho do sistema proposto em um ambiente representativo de operações reais de perfuração.

3.2 Metodologia Experimental

3.2.1 Local dos experimentos e equipamentos utilizados

Os experimentos foram realizados pelas equipes dos Grupos de Pesquisa do Laboratório de Escoamento de Fluidos Giulio Massarani da UFRRJ (LEF/UFRRJ) e do Laboratório de Separação Sólido-Líquido da Universidade Federal de Uberlândia (LSSL/UFU), utilizando uma peneira vibratória industrial da marca M-I SWACO.

A peneira é a mesma empregada em unidades de controle de sólidos em operações de perfuração de poços de petróleo e é ilustrada na Figura 3.2.

Figura 3.2 - Peneira Vibratória M-I SWACO da FEQ/UFU.




Fonte: Elaborada pelo autor.

O esquema experimental da unidade pode ser visualizado na *Figura 3.3* que ilustra (1) bomba de alimentação/recirculação, (2) sensor de vazão eletromagnético para medição do fluxo de alimentação, (3) duto de alimentação de suspensão para a peneira, (4) cesto da peneira vibratória, (5) motovibradores da peneira vibratória, (6) câmera, (7) recipiente de coleta para pesagem dos sólidos retidos pela tela, (8) calha de retorno dos sólidos retidos pela tela, (9) calha de retorno do líquido passante pelas telas, (10) motor de agitação do tanque de suspensão, (11) tanque de armazenamento da suspensão sólido-líquido e (12) área de enquadramento da câmera do celular.

A peneira foi instalada em bancada experimental no LSSL/UFU, permitindo o controle independente das condições operacionais e a aquisição de imagens de forma sistemática e reproduzível. O equipamento foi operado com tela classificada como API 200, com um

comprimento de aproximadamente 115 cm e 57 cm altura, selecionada por sua capacidade de retenção de partículas finas, característica relevante para o estudo do comportamento dos sólidos durante o escoamento na peneira.

Figura 3.3 - Esquema da unidade experimental com seus principais componentes.



Fonte: Elaborado pelo autor.

3.2.2 Composição da suspensão

A suspensão utilizada nos experimentos foi formulada de modo a simular um fluido de perfuração típico à base de água, contendo partículas sólidas representativas de cascalhos gerados durante a perfuração. A composição da suspensão foi definida conforme segue:

- 98% de fase líquida, composta por água contendo 3% em massa de argila esmectita, com o objetivo de reproduzir propriedades reológicas características de fluidos de perfuração;
- 2% de fase sólida, composta por areia, utilizada como material particulado para simular os cascalhos provenientes da fragmentação das formações rochosas.

Essa composição permitiu obter um escoamento com comportamento representativo das condições e do escoamento dos cascalhos encontradas em peneiras vibratórias em poços de perfuração, mantendo estabilidade durante a operação e repetibilidade entre os ensaios.

3.2.3 Condições operacionais

Os testes experimentais foram conduzidos variando-se dois parâmetros operacionais principais: velocidade de rotação da peneira e vazão de alimentação da suspensão. As condições avaliadas foram:

Velocidades de rotação: 1200 RPM e 1800 RPM.

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

A combinação desses parâmetros resultou em um conjunto de seis condições operacionais distintas, permitindo avaliar o comportamento do sistema sob diferentes regimes de operação.

3.2.4 Aquisição de vídeos e imagens do experimento

Para cada condição operacional, foi gravado um vídeo com duração de aproximadamente 5 minutos, totalizando seis vídeos experimentais. A aquisição foi realizada por meio de uma câmera posicionada acima da peneira vibratória, de modo a capturar a região de praia, onde ocorre o escoamento predominante dos sólidos e onde se concentram informações relevantes sobre o processo de separação.

Os vídeos foram gravados em qualidade *full HD* (1080p) com taxa de 30 quadros por segundo (QPS) e resolução suficiente para permitir a identificação visual dos sólidos sobre a tela da peneira. A partir desses vídeos, foram extraídas imagens estáticas em intervalos de 1 quadro por segundo (QPS), sendo descartado em cada experimento alguns segundos pela até chegarem as imagens da suspensão, resultando em um total de 1233 imagens, utilizadas posteriormente na etapa computacional para treinamento da rede neural e validação do modelo.

3.3 Metodologia computacional

A metodologia computacional desenvolvida neste trabalho teve como objetivo a segmentação da suspensão presente sobre a peneira vibratória, seguida da quantificação da área da tela preenchida por cascalhos (AP), da velocidade média de escoamento dos sólidos da suspensão e da extração de descritores morfológicos das partículas.

Para isso, foram adotadas duas abordagens baseadas em aprendizado profundo, uma das quais fundamentada em segmentação semântica por U-Net, implementada no ambiente MATLAB, e outra baseada em detecção por YOLOv8, implementada em Python. Ambas as abordagens compartilharam o mesmo fluxo conceitual de processamento, diferindo principalmente na estratégia de inferência e representação das regiões segmentadas.

A metodologia computacional pode ser dividida nas seguintes etapas principais:

- i. Construção e rotulagem do banco de dados (*ground truth*);
- ii. Aumento artificial de dados (*data augmentation*);
- iii. Treinamento dos modelos de segmentação/detecção;
- iv. Seleção do modelo com melhor desempenho;
- v. Aplicação do modelo no software desenvolvido para estimativa das variáveis de interesse.

A escolha das arquiteturas U-Net e YOLOv8 foi baseada no equilíbrio entre desempenho, custo computacional, simplicidade de implementação e adequação ao problema proposto. A U-Net foi selecionada para a tarefa de segmentação semântica, por apresentar excelente desempenho em bases de dados reduzidas, característica particularmente relevante neste trabalho, além de possuir arquitetura consolidada e amplamente validada em aplicações de segmentação de imagens e ter sido escolhida no escopo da concepção do projeto. Já a YOLOv8 foi escolhida para a detecção de objetos devido à sua elevada velocidade de inferência, robustez e facilidade de treinamento, sendo especialmente adequada para aplicações em tempo real e ambientes industriais, nos quais respostas rápidas são essenciais para monitoramento contínuo.

Em contraste, modelos como Mask R-CNN, embora bastante precisos, apresentam maior complexidade arquitetural e custo computacional mais elevado, o que pode dificultar sua aplicação em sistemas embarcados ou em cenários que demandem processamento em tempo real. O DeepLab, por sua vez, é altamente eficiente em segmentação semântica, porém geralmente requer maior capacidade computacional e conjuntos de dados extensos para pleno aproveitamento de seu potencial. Já o Detectron2, através de uma plataforma que implementa diferentes modelos avançados, incluindo o próprio Mask R-CNN, implicando maior complexidade de configuração e integração. Dessa forma, U-Net e YOLOv8 mostraram-se alternativas mais adequadas aos objetivos desta pesquisa, ao oferecerem desempenho satisfatório aliado à viabilidade prática de implementação.

De forma complementar, ambas as arquiteturas podem ser utilizadas em conjunto: a U-Net fornecendo informações detalhadas sobre cobertura, comportamento do material durante o

escoamento e cálculo de métricas geométricas associadas aos cascalhos, enquanto a YOLOv8 atua na detecção rápida de eventos críticos e objetos de interesse, características importantes para integração com sistemas automáticos de supervisão e controle. Assim, a escolha entre uma ou outra abordagem depende do balanço desejado entre precisão espacial, velocidade computacional e tipo de variável de processo a ser monitorada.

3.3.1 Construção do banco de dados e rotulagem das imagens

A partir dos vídeos experimentais obtidos durante os ensaios na peneira vibratória, foram extraídas 1233 imagens representativas do processo de separação sólido-líquido. Essas imagens correspondem a diferentes condições operacionais de rotação e vazão, garantindo variabilidade do processo analisado.

A rotulagem das imagens foi realizada por meio de segmentação supervisionada, na qual cada pixel da imagem é classificado como pertencente à suspensão sobre a peneira (*foreground*) ou ao fundo (*background*). Esse processo resultou na geração de máscaras binárias, utilizadas como *ground truth* para o treinamento das redes neurais.

3.3.1.1 Segmentação assistida com a ferramenta Roboflow

A etapa de rotulagem das imagens, necessária para a construção do *ground truth* utilizado no treinamento dos modelos de aprendizado profundo, foi realizada através da ferramenta Roboflow, uma plataforma que utiliza o auxílio do *Segment Anything Model 2* (SAM 2), um modelo de segmentação fundamentado em aprendizado profundo e que desenvolvido para gerar máscaras precisas a partir de interações mínimas do usuário.

Segundo Ravi (2024), o SAM 2 pertence à classe de modelos de segmentação baseada em *prompts*, nos quais a delimitação das regiões de interesse pode ser guiada por informações aproximadas fornecidas pelo operador, como pontos, traços, polígonos ou caixas delimitadoras iniciais. A partir desses *prompts*, o modelo estima automaticamente a fronteira da região a ser segmentada, gerando uma máscara binária de alta precisão.

Matematicamente, o SAM 2 aprende uma função de mapeamento, segundo a (Equação 3).

$$f(I, p) \rightarrow M \quad (\text{Equação 3})$$

em que:

- I representa a imagem de entrada;

- p corresponde ao conjunto de *prompts* fornecidos pelo usuário (pontos indicativos da região de interesse),
- M é a máscara de segmentação gerada, definida segundo a (Equação 4).

$$M(x, y) = \begin{cases} 1, & \text{se o pixel pertence à suspensão} \\ 0, & \text{caso contrário} \end{cases} \quad (\text{Equação 4})$$

Diferentemente de métodos tradicionais de segmentação manual pixel a pixel, o SAM 2 utiliza um modelo de base treinado em larga escala, capaz de generalizar para diferentes tipos de imagens e objetos sem a necessidade de treinamento específico para cada novo conjunto de dados. Essa característica pode ser observada na Figura 3.4 e torna o método particularmente adequado para aplicações industriais, nas quais as condições de iluminação, textura e aparência dos materiais podem variar significativamente.

Figura 3.4 - Exemplo de uma segmentação no Roboflow (polígonos amarelos - suspensão) do experimento realizado na UFU em 1200 RPM e 20 m³/h.



Fonte: Elaborada pelo autor.

No contexto deste trabalho, o SAM 2 foi empregado como ferramenta de apoio à anotação, e não como modelo final de inferência. O procedimento adotado consistiu em:

- i. Selecionar manualmente regiões aproximadas correspondentes à suspensão sobre a peneira;
- ii. Aplicar o SAM 2 para gerar automaticamente a máscara inicial;
- iii. Revisar e, quando necessário, corrigir manualmente as bordas da segmentação;
- iv. Consolidar a máscara final como ground truth para treinamento dos modelos U-Net e YOLOv8.

Esse processo híbrido (automático e revisão humana) permite reduzir significativamente o tempo de anotação em comparação com a rotulagem totalmente manual, padronizar os critérios de segmentação entre diferentes imagens e minimizar erros sistemáticos associados à subjetividade do anotador.

Além disso, o uso do SAM 2 contribuiu para a obtenção de máscaras com contornos mais realistas e contínuos, especialmente em regiões onde a interface entre a suspensão e o fundo apresenta gradientes suaves de intensidade ou transições difusas.

É importante destacar que, embora o SAM 2 tenha sido utilizado para gerar máscaras iniciais, o aprendizado efetivo do padrão de segmentação foi realizado pelos modelos treinados (U-Net e YOLOv8), os quais passaram a operar de forma autônoma dentro do software desenvolvido na etapa de análise dos vídeos experimentais.

3.3.1.2 Aumento de dados (*data augmentation*) e divisão do conjunto amostral

Com o objetivo de aumentar a robustez do modelo e reduzir o risco de sobreajuste (*overfitting*), foram aplicadas técnicas de aumento artificial de dados (*data augmentation*) sobre o conjunto original de imagens. A partir das 1233 imagens iniciais, após a aplicação do *data augmentation*, o banco de dados final passou para 6615 imagens para realizar o treino das redes neurais. As transformações aplicadas incluem:

- i. espelhamento horizontal;
- ii. variação de saturação (entre -25% e +25%);
- iii. variação de exposição (entre -10% e +10%);
- iv. conversão parcial para escala de cinza (aplicado a 15% das imagens);
- v. composição do tipo mosaico das imagens.

Essa divisão garante uma base suficientemente ampla para aprendizado do modelo, mantendo conjuntos independentes para validação e avaliação final. A exportação do banco de dados final foi realizada com imagens de dimensão reduzida (640x640 pixels), de modo a otimizar e acelerar o treinamento da rede U-Net, sem perder a qualidade da mesma, visto que quanto maior a dimensão da imagem, mais demorado será a etapa do treinamento da rede.

A divisão do conjunto de dados em 70% para treinamento, 25% para validação e 5% para teste foi definida de modo a equilibrar as diferentes etapas do desenvolvimento do modelo. A maior parcela foi destinada ao treinamento, garantindo quantidade suficiente de amostras para que a rede neural aprendesse padrões representativos e apresentasse melhor capacidade de generalização. O conjunto de validação recebeu uma fração mais elevada do que a usualmente

empregada, pois foi utilizado para o acompanhamento do processo de treinamento, ajuste de hiperparâmetros e monitoramento de métricas ao longo das épocas. Por fim, o conjunto de teste foi mantido exclusivamente para a avaliação final e imparcial da rede após o treinamento, sendo considerado suficiente para verificar o desempenho obtido sem comprometer a disponibilidade de dados nas etapas anteriores.

3.3.2 Treinamento da rede U-Net e avaliação do efeito de hiperparâmetros

O treinamento da U-Net foi realizado no Matlab versão 2024, a partir do *ground truth* obtido pela segmentação realizada no software Roboflow. Durante o processo, foram avaliadas diferentes configurações de arquitetura, visando maximizar a acurácia do modelo. A Tabela 3.1 a seguir, foram listadas os hiperparâmetros que foram avaliados:

Tabela 3.1 - Tabela de hiperparâmetros da rede U-Net e respectivas função e impacto.

Hiperparâmetro	Função	Impacto
<i>PatchSize</i> (Tamanho do Patch)	Define a dimensão espacial das sub-regiões da imagem processadas individualmente pela rede.	Determina a granularidade da entrada. Patches menores economizam memória, mas perdem contexto global. Patches maiores capturam mais contexto, mas exigem maior custo computacional.
<i>EncoderDepth</i> (Profundidade do Codificador)	Estabelece o número de níveis de redução de dimensionalidade (<i>downsampling</i>) na etapa de contração da U-Net.	Controla a hierarquia de características. Profundidades maiores permitem aprender características semânticas mais abstratas e complexas, enquanto menores focam em detalhes de baixo nível.
<i>KernelSize</i> (Dimensão do Kernel)	Determina a dimensão espacial (N×N) da matriz de filtro utilizada nas operações de convolução.	Define o campo receptivo local imediato. <i>Kernels</i> menores detectam detalhes finos e bordas; <i>kernels</i> maiores agregam informações de uma área mais ampla em uma única operação.
<i>NumFilters</i> (Número de Filtros)	Define a quantidade de mapas de características (feature maps) gerados em cada camada convolucional.	Representa a “largura” da rede. Aumentar este valor permite que o modelo aprenda uma maior diversidade de padrões simultâneos (texturas, formas), ao custo de maior processamento.

Fonte: Elaborado pelo autor.

A taxa de desativação de neurônios (*DropoutRate*) foi mantido fixo em 0,5 (50%) em todas as configurações testadas, atuando como mecanismo de regularização para reduzir o sobreajuste (*overfitting*).

O desempenho das diferentes arquiteturas foi avaliado por métricas clássicas de segmentação, com destaque para a Interseção sobre União (*Intersection over Union* - IoU) média, utilizada como critério principal para seleção do melhor modelo.

3.3.3 Treinamento da rede YOLOv8

O desenvolvimento e treinamento da rede neural para detecção de objetos foram realizados em ambiente Python versão 3.12, utilizando a biblioteca Ultralytics, que disponibiliza a implementação oficial da arquitetura YOLOv8 (JOCHER *et al.*, 2023). Diferentemente da abordagem de segmentação semântica pixel a pixel utilizada na U-Net, o treinamento da YOLOv8 teve como foco a detecção e delimitação das regiões de suspensão por meio de caixas delimitadoras (*bounding boxes*).

Para a execução do treinamento, foi desenvolvido um algoritmo específico que integra uma interface gráfica baseada na biblioteca Tkinter, permitindo a configuração dinâmica dos hiperparâmetros e a seleção dos diretórios de dados sem a necessidade de alteração direta no código-fonte. O processo de treinamento baseou-se na técnica de aprendizado por transferência (*transfer learning*), utilizando como ponto de partida os pesos do modelo pré-treinado YOLOv8n (*Nano*). Esta variante foi selecionada por ser a versão mais leve da família YOLOv8, oferecendo um equilíbrio adequado entre velocidade de inferência e precisão para a capacidade computacional disponível, conforme discutido por Terven *et al.* (2023).

O conjunto de dados utilizado para o treinamento foi o mesmo empregado na rede U-Net. As imagens e suas respectivas anotações (convertidas para o formato YOLO) foram organizadas e referenciadas através de um arquivo de configuração *yaml*, conforme exigido pelo framework da Ultralytics.

A configuração dos hiperparâmetros para o treinamento, inserida via interface do algoritmo desenvolvido, foi definida da seguinte forma:

- Dimensão das imagens (*imgsz*): 640x640 pixels, redimensionamento padrão para garantir a eficiência da arquitetura YOLO;
- Tamanho do lote (*batch size*): 16 imagens processadas por iteração, adequado à memória disponível no hardware utilizado;
- Épocas (*epochs*): 50 ciclos completos de treinamento sobre o conjunto de dados;
- Paciência (*patience*): 5 épocas. Este parâmetro de parada antecipada (*early stopping*) interrompe o treinamento caso não haja melhoria nas métricas de validação por 5 épocas consecutivas, prevenindo o sobreajuste (*overfitting*).

O algoritmo de treinamento invoca a classe YOLO da biblioteca Ultralytics e executa o método `.train()`, processando o banco de dados conforme os parâmetros estipulados. Durante o processo, o modelo otimiza os pesos para minimizar as funções de perda relacionadas à localização das caixas (*box loss*), classificação dos objetos (*cls loss*) e distribuição focal (*dfl loss*).

3.3.4 Equacionamento dos parâmetros operacionais

O equacionamento dos parâmetros operacionais foi fundamentado na análise de imagens dos vídeos do processo, a partir das quais são extraídas informações quantitativas por meio de técnicas de visão computacional e processamento de imagens. Os dois parâmetros principais considerados são: Área da tela preenchida por cascalhos (%), e a velocidade média de escoamento dos sólidos da suspensão (cm/s).

Para o cálculo da Área Preenchida (AP), o algoritmo processa cada QPS, identificando regiões poligonais predefinidas, preenchendo-as e calculando individualmente o número total de pixels classificados como pertencentes ao objeto de interesse (área ocupada pela suspensão). Esse número de pixels é então comparado com número total de pixel da área que está sendo analisada (área da peneira), evidenciado pela (Equação 5).

$$AP (\%) = \frac{\text{pixels objetos detectados}}{\text{pixels totais da imagem}} \times 100\% \quad (\text{Equação 5})$$

Com o objetivo de estimar a velocidade de escoamento através do software, é preciso calcular o deslocamento dos objetos de interesse entre frames consecutivos ao longo do vídeo. Esse deslocamento espacial é calculado de acordo com a (Equação 6).

$$\Delta x = x_{t+1} - x_t \text{ e } \Delta y = y_{t+1} - y_t \quad (\text{Equação 6})$$

Em seguida, o algoritmo calcula a distância mínima usando a diferença euclidiana em um espaço bidimensional, entre os centroides das detecções atuais (x_{i+1}, y_{i+1}) e as detecções anteriores (x_i, y_i), descrito com a (Equação 7).

$$d_{\min} = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (\text{Equação 7})$$

A distância em pixel (d_{pixels}) é convertida então em centímetros (d_{cm}), multiplicando-se a distância percorrida pelo objeto entre os quadros pela razão entre o comprimento da seção em centímetros (L_{cm}), e o valor correspondente em pixels (L_{pixels}), conforme a (Equação 8).

$$d_{\text{cm}} = d_{\text{pixels}} \times \frac{L_{\text{cm}}}{L_{\text{pixels}}} \quad (\text{Equação 8})$$

O cálculo da velocidade da suspensão estimada pelo software, através da peneira então pode ser calculada para todo o vídeo, fazendo uma média de todos os objetos de interesse presentes na cena, seja por análise *off-line*, ou análise em tempo real, por meio da (Equação 9).

$$V = \frac{D_{\text{cm}}}{\Delta t} \quad (\text{Equação 9})$$

Para avaliar a precisão dos resultados, foram utilizadas duas abordagens complementares:

- i. Comparação entre a porcentagem de área preenchida detectada pelo sistema de visão computacional e o valor de referência para a área preenchida esperada (AP_E). A AP_E foi calculada diretamente a partir das máscaras binárias geradas com base no *groundtruth* das máscaras com as anotações dos polígonos manuais da região de interesse, servindo como parâmetro de referência para a avaliação.
- ii. A Velocidade Seccional (VS), descrita na (Equação 10), foi definida como um parâmetro teórico experimental de referência para se aproximar de uma velocidade teórica da suspensão, calculada pela razão entre a vazão volumétrica da suspensão coletada (Q_{coletada}) e a área da seção transversal ao escoamento na extremidade da peneira ($A_{\text{seccional}}$).

$$VS = \frac{Q_{\text{coletada}}}{A_{\text{seccional}}} \quad (\text{Equação 10})$$

Por limitações experimentais, não foi possível realizar a medição direta da altura ocupada pelo fluido na tela por meio de sensoriamento. Assim, adotou-se um valor fixo de 0,5 cm para a altura da suspensão em todas as condições operacionais. Além disso, assumiu-se que todo o comprimento da extremidade da peneira estava ocupado por sólidos em escoamento, o que permitiu considerar a largura da peneira como o comprimento da seção. Dessa forma, a área

seccional foi estimada como o produto entre a altura fixa da lâmina de fluido e a largura da tela, possibilitando a obtenção de uma velocidade média teórica para comparação com os valores inferidos pelo modelo.

Foram calculados também o Erro Relativo Absoluto (ER_A) e o Erro Relativo Absoluto Médio (ER_{AM}), por meio da (Equação 11 e (Equação 12).

$$ER_A = \frac{|\text{Real} - \text{Calculado}|}{|\text{Real}|} \quad (\text{Equação 11})$$

$$ER_{AM} = \frac{1}{n} \sum_{i=1}^n \frac{|\text{Real} - \text{Calculado}|}{|\text{Real}|} \quad (\text{Equação 12})$$

3.3.5 Configuração do ambiente computacional e custo de treinamento e de seleção de hiperparâmetros da U-Net

O treinamento e a avaliação dos modelos de redes neurais profundas empregados neste trabalho constituíram uma etapa de alto custo computacional, em função do volume de dados, do número de iterações por época e, principalmente, da necessidade de repetir o procedimento para diferentes configurações de hiperparâmetros no caso da U-Net. Assim, esta subseção descreve a plataforma computacional utilizada, bem como o procedimento adotado para seleção da melhor configuração e o tempo associado às rotinas de treinamento.

3.3.5.1 Configurações do computador utilizado para o treinamento da U-Net

Os treinamentos foram executados em um computador com sistema operacional Microsoft Windows 11 Pro, arquitetura x64, equipado com processador Intel Core i7-13700 (13ª geração) e 32,0 GB de memória RAM instalada. O processamento gráfico foi realizado em GPU dedicada NVIDIA GeForce RTX 5070 Ti, operando em regime de GPU única (single GPU) durante o treinamento. O sistema também dispõe de controlador NVMe (NVM Express), utilizado como base de armazenamento para o sistema e para o acesso aos dados, contribuindo para reduzir gargalos de leitura/gravação durante a etapa de treinamento e validação.

3.3.5.2 Procedimento de seleção da melhor configuração de hiperparâmetros (U-Net)

A seleção da arquitetura final da U-Net foi conduzida por uma variação dos hiperparâmetros, nos quais foram avaliadas combinações entre: *PatchSize*, *EncoderDepth*,

KernelSize e *NumFilters*, mantendo-se fixa a taxa de *dropout* (taxa de desligamento) em 0,5 (50%) ao longo de todos os treinamentos, a fim de padronizar o nível de regularização e permitir comparação direta entre as configurações. Para cada combinação avaliada, o treinamento foi executado do início ao fim do critério de parada adotado e, ao final, o desempenho foi quantificado por métricas de validação, incluindo acurácia global e IoU (*Intersection over Union*), registradas para comparação entre os cenários.

O procedimento adotado foi fixar o conjunto de dados e o protocolo de divisão/validação, definir a lista de combinações de hiperparâmetros a serem testadas, treinar a rede para cada configuração e registrar métricas de validação de cada execução. Após todo o treinamento ser concluído, a configuração com melhor equilíbrio de desempenho (acurácia e IoU) foi escolhida, visando não apenas maximizar a acurácia global, mas também obter melhor concordância espacial entre máscara prevista e referência (IoU), o que é essencial em segmentação.

3.3.5.3 Tempo de treinamento do melhor modelo e implicações no custo computacional

Como referência do custo computacional envolvido, para a configuração que apresentou o melhor desempenho entre as avaliadas, registrou-se acurácia de validação aproximadamente de 95%, com treinamento encerrado por critério de validação. O treinamento iniciou em 30-Apr-2025 22:21:57 e apresentou tempo decorrido de 2586 min 10s, equivalente a aproximadamente 43 horas. A execução foi conduzida com taxa de aprendizado constante de 0,001, validação realizada a cada 200 iterações, com 2315 iterações por época, totalizando 28200 iterações até o encerramento (época 13 de 300), em regime de single GPU.

Esses valores evidenciam que a etapa de busca por hiperparâmetros não é marginal: ao repetir o treinamento para múltiplas combinações (conforme tabela de estudo dos hiperparâmetros), o esforço total se acumula e demanda longos períodos de execução contínua, além de acompanhamento do comportamento de validação para garantir que os modelos sejam comparados sob condições equivalentes. Na prática, a seleção da melhor estrutura foi composta por sucessivas execuções completas de treinamento/validação realizadas de acordo com , com tempos variando conforme a convergência de cada configuração, caracterizando uma das fases mais custosas deste estudo do ponto de vista computacional.

3.3.6 Configuração do ambiente computacional e custo de treinamento da YOLOv8

De forma análoga, porém realizando o treinamento em um computador com uma capacidade computacional inferior, devido à limitação de infraestrutura. O critério de desempenho e as métricas da YOLOv8 na detecção de objetos (distintos da segmentação semântica), o impacto computacional é mais otimizado nessa arquitetura e, por estar sendo desenvolvido o software em ambiente Python em paralelo com o código em Matlab, foi realizado nas seguintes configurações a seguir.

3.3.6.1 Configurações do computador utilizado para o treinamento da YOLOv8

O treinamento do modelo YOLOv8 foi realizado em um computador com um processador Intel(R) Core(TM) i5-1035G1 CPU @ 1.00 GHz (1,19 GHz) e 8,0 GB de memória RAM instalada, dos quais aproximadamente 5,55 GB estavam disponíveis para utilização durante os experimentos. Essa configuração foi utilizada para todas as etapas de treinamento, validação e testes do modelo YOLOv8.

3.3.7 Configuração de treinamento da rede YOLOv8 (Ultralytics)

O treinamento do detector YOLOv8 foi realizado por meio da biblioteca Ultralytics, utilizando o modo *train* do framework. O procedimento consistiu em (i) selecionar o arquivo de configuração do conjunto de dados no formato YAML (que define caminhos para *train/val/test*, nomes das classes e demais metadados) e (ii) executar o treinamento a partir de um conjunto de hiperparâmetros explicitamente definidos no script de treinamento anexado.

O treinamento foi inicializado a partir de um arquivo de pesos pré-treinado no padrão Ultralytics, indicado no script como *yolov8n.pt*. Esse arquivo corresponde à variante YOLOv8n (*nano*), isto é, a versão mais leve da família YOLOv8, usada como ponto de partida para aprendizado por transferência: em vez de treinar do zero, a rede inicia com pesos já ajustados em uma base ampla (por exemplo, COCO) e é então refinada (*fine-tuning*) para o seu domínio de imagens. Na prática, isso reduz tempo de convergência

O número de épocas foi definido como 50, imagem de entrada 640x640 pixels, *batch* (quantidade de imagens por iteração) de 16 e o *early stopping* de 5 antes de interromper o treinamento.

3.3.7.1 Tempo de treinamento da rede YOLOv8

Com a combinação das configurações do computador que foi treinado e os hiperparâmetros e a natureza da arquitetura da YOLOv8 que foi projetada para ser mais otimizada do que a U-Net, o modelo que teve melhor desempenho teve um custo computacional de aproximadamente 24 horas de treinamento.

CAPÍTULO 4. RESULTADOS E DISCUSSÃO

Resumo

O quarto capítulo apresenta e discute os resultados obtidos a partir do treinamento das redes neurais e da aplicação dos softwares desenvolvidos para o monitoramento da peneira vibratória. Inicialmente, avalia-se o desempenho do treinamento dos modelos, onde a rede U-Net alcançou acurácia de 95% e IoU de 85% após otimização de hiperparâmetros, enquanto o modelo YOLOv8 demonstrou robustez com $mAP@50$ de 0,877 e alta precisão na detecção de objetos. Em seguida, compara-se a eficácia das estimativas de área da tela preenchida por cascalhos e a velocidade média de escoamento dos sólidos da suspensão geradas pelos softwares em MATLAB e Python com os valores de referência experimentais. A discussão evidencia que ambos os modelos capturaram adequadamente as tendências físicas do escoamento, como o aumento da velocidade proporcional à vazão, embora tenham sido observadas limitações na segmentação em condições de alta saturação da tela (acima de 70% de ocupação). São apresentadas as interfaces gráficas desenvolvidas para o operador, demonstrando a visualização em tempo real das máscaras de segmentação, *bounding boxes* e gráficos de desempenho. Adicionalmente, discute-se a implementação preliminar de descritores morfológicos como ferramenta complementar para caracterização dos sólidos, demonstrando o potencial dessa abordagem para extração de informações adicionais sobre o comportamento dos cascalhos, ainda que necessite de validação futura mais aprofundada.

Palavras-chave: resultados experimentais; área preenchida; velocidade média; U-Net; YOLOv8


4.1 Resultados dos treinamentos dos modelos de redes neurais profundas

A qualidade de um bom treinamento de uma rede neural convolucional é um fator determinante para o desenvolvimento de um sistema de visão computacional, visto que a confiabilidade dos cálculos subsequentes da área preenchida e velocidade de escoamento está atrelado a esse fundamento. Dessa forma, antes da aplicação dos modelos no monitoramento do processo, foi realizada uma análise detalhada do desempenho dos treinamentos da U-Net (MATLAB) e do YOLOv8 (Python), utilizando métricas apropriadas a cada arquitetura e análises visuais de cada modelo durante o treinamento.

4.1.1 Desempenho do treinamento da U-Net (MATLAB)

O treinamento da U-Net foi conduzido a partir do conjunto de dados rotulado no Roboflow, devidamente identificado, segmentado e cada imagem com sua respectiva máscara binária. Um exemplo do *input* da imagem com sua correspondente máscara binária, sendo o gabarito que a rede considera como *groundtruth* na etapa de aprendizado, pode ser observado na Figura 4.1.

Figura 4.1. Imagem original da suspensão na peneira (a) e sua respectiva máscara binária (b) em uma velocidade de 1200 RPM e 20m³/h de vazão.



Fonte: Elaborado pelo autor.

De modo a analisar qual combinação de hiperparâmetros proporcionaria a melhor acurácia da rede U-Net, realizou-se um conjunto de treinos variando os principais

hiperparâmetros a fim de avaliar qual deles teria maior impacto no propósito final de melhor identificar o objeto de interesse do trabalho.

O resultado do estudo com a variação dos hiperparâmetros pode ser analisado de acordo com os resultados apresentados na

Tabela 4.1. As métricas utilizadas para avaliação do desempenho do treinamento foram a acurácia e o *Intersection over Union* (IoU), que nos retorna uma avaliação mais adequada, pois considera simultaneamente falsos positivos e falsos negativos e sua respectiva (Equação 13).

$$IoU = \frac{\text{Número de pixels corretamente segmentados}}{\text{Número total de pixels pertencentes à união entre predição e ground truth}} \quad (\text{Equação 13})$$

Tabela 4.1 – Resultado da variação do estudo dos hiperparâmetros de treinamento selecionados da rede U-Net.

PatchSize	EncoderDepth	KernelSize	NumFilters	Acurácia	IoU
64	4	3	128	59%	30%
64	4	5	64	60%	30%
64	5	3	64	94%	83%
64	3	3	64	95%	85%
128	3	3	64	71%	64%
128	4	3	128	45%	23%
128	4	5	64	62%	31%
128	5	3	64	68%	49%


Fonte: Elaborado pelo autor.

Ao observar o resultado do estudo dos hiperparâmetros realizado, fica evidenciado que a U-Net com melhor desempenho foi aquela com um *PatchSize* de tamanho 64, *EncoderDepth* 3, *KernelSize* 3, *NumFilters* 64, que atingiu acurácia de validação de aproximadamente 95% e IoU de 85%. As curvas do progresso do treinamento da rede U-Net podem ser observadas na Figura 4.2, em que se observa a curva de acurácia do modelo e também da *Loss Function* ao longo das iterações.

A análise do desempenho do modelo neural utilizado, realizada por comparação visual e apresentada na Figura 4.3, evidencia a eficácia do método na detecção da suspensão. Ao se observar a imagem segmentada em relação à imagem original, nota-se que o modelo é capaz de

identificar de forma consistente as regiões correspondentes à suspensão, distinguindo-as adequadamente do fundo e de demais elementos presentes na cena.

Figura 4.2. Curva de treinamento da rede U-Net.



Fonte: Elaborado pelo autor.

Figura 4.3. Resultado da segmentação da suspensão na peneira: (a) imagem original adquirida durante o experimento; (b) máscara de segmentação gerada pela U-Net, evidenciando as regiões classificadas como suspensão.



(a)

(b)


Fonte: Elaborado pelo autor.

A matriz de confusão normalizada apresentada na

Figura 4.4 ilustra o desempenho do modelo de segmentação na classificação dos pixels entre as classes Background e Areia. Cada linha representa a classe verdadeira (rótulo de referência), enquanto cada coluna representa a classe predita pelo modelo. Os valores percentuais indicam a proporção de acertos e erros em relação ao total de pixels de cada classe. Observa-se que 94,58% dos pixels pertencentes ao *Background* foram corretamente classificados como tal, enquanto 5,42% foram erroneamente identificados como *Areia*. De forma análoga, 95,57% dos pixels realmente pertencentes à classe *Areia* foram corretamente detectados pelo modelo, ao passo que 4,43% foram confundidos com *Background*.

Esses resultados evidenciam uma elevada capacidade discriminativa do modelo, com baixos índices de falsos positivos e falsos negativos, indicando que a rede consegue separar de maneira consistente a suspensão arenosa do fundo da imagem.

Figura 4.4. Matriz de confusão normalizada para as classes Areia e Background.




Fonte: Elaborado pelo autor.

O histograma da Figura 4.5 apresenta o histograma do *Image Mean Intersection over Union* (IoU médio por imagem), que descreve a distribuição do desempenho do modelo de segmentação ao longo do conjunto de validação. Observa-se que a maioria das imagens apresenta valores de IoU concentrados entre aproximadamente 0,75 e 0,95, indicando que, na maior parte dos casos, há uma sobreposição substancial entre a segmentação predita e o *ground truth*. A presença de poucas imagens com IoU abaixo de 0,6 sugere que o modelo

ocasionalmente enfrenta maior dificuldade em cenários mais complexos ou com menor contraste, mas, de maneira geral, o desempenho é consistente e elevado.

Figura 4.5. Histograma do IoU médio obtido para o conjunto de validação da U-Net.



Fonte: Elaborado pelo autor.

4.1.2 Desempenho do treinamento da YOLOv8 (Python)

De forma análoga, o mesmo banco de dados com as imagens originais e binarizadas foi utilizado para realizar o treinamento da rede neural em ambiente Python. O modelo YOLOv8 foi treinado utilizando a implementação da biblioteca Ultralytics. No presente trabalho, os principais parâmetros configurados foram: número de épocas de treinamento (épocas = 50), tamanho das imagens de entrada (*imagesize* = 640×640 pixels), tamanho de lote (batch = 16) e critério de parada antecipada (*patience* = 5). Os demais parâmetros como taxa de aprendizado inicial (0.01), funções de perda (0.0005) foram mantidos segundo os valores *default* da implementação Ultralytics YOLOv8 utilizada.

Para realizar a análise dos gráficos gerados pelo treinamento da YOLOv8, as definições matemáticas das métricas analisadas serão apresentadas a seguir. A Precisão (*Precision*), evidenciada pela (Equação 14, mensura a qualidade das detecções positivas. TP (*True Positives*): Instâncias da suspensão detectadas corretamente e FP (*False Positives*): Fundo (background) classificado incorretamente como o objeto de interesse. No treinamento, a precisão final chegou a aproximadamente 0,86.

$$Precision = \frac{TP}{TP + FP} \quad (\text{Equação 14})$$

O parâmetro *Recall*, definido pela (Equação 15) calcula a quantidade de objetos reais que foram encontrados. FN (*False Negatives*) são as instâncias da suspensão que o modelo não detectou (classificou como fundo). O modelo atingiu um *Recall* de aproximadamente 0,791 na última época.


$$Recall = \frac{TP}{TP + FN} \quad (\text{Equação 15})$$

O *mAP* é a área sob a curva *Precision-Recall*, em que é calculado a média da precisão para todas as classes, considerando positivo apenas quando o $IoU \geq 0.50$, evidenciado pela (Equação 16 **Erro! Fonte de referência não encontrada.** Em que AP é a Average Precision calculada pela integral da curva da Figura 4.7. Nos resultados, este valor foi 0,877.

$$mAP = \sum AP \quad (\text{Equação 16})$$

A evolução das métricas de treinamento consiste na verificação da convergência do modelo ao longo das épocas. A Figura 4.6 apresenta o comportamento das funções de perda (*loss functions*) e das métricas de validação durante as 15 épocas de treinamento.

Figura 4.6. Gráficos de evolução das perdas de treinamento e validação (box, classificação e DF) e métricas de desempenho (Precisão, Recall, mAP50) ao longo do treinamento.




Fonte: Elaborado pelo autor.

Ao analisar os gráficos gerados pelo treinamento do modelo observa-se um consistente aprendizado pelo modelo, caracterizado pela redução progressiva das perdas de treinamento (train/box_loss, train/cls_loss, train/df_l_loss). O modelo demonstrou rápida convergência, atingindo estabilidade nas métricas de precisão média (mAP) já nas primeiras épocas. Ao final da 15ª época, o modelo alcançou uma precisão de aproximadamente 0,859 e um mAP50 de 0,877, indicando uma alta capacidade de detecção dos objetos de interesse. A perda de validação (val/box_loss) estabilizou em torno de 1,36, sugerindo que o modelo não sofreu de sobreajuste (*overfitting*) durante este ciclo curto de treinamento.

Para avaliar o compromisso entre a capacidade do modelo de não gerar falsos positivos (Precisão) e sua capacidade de encontrar todas as instâncias positivas (*Recall*), a curva *Precision-Recall* (PR) pode ser analisada pela Figura 4.7.

Figura 4.7 - Curva Precisão-Revocação (*Precision-Recall*) para o objeto de interesse, evidenciando a área sob a curva mAP@0.5.




Fonte: Elaborado pelo autor.

A Curva PR apresentada na Figura 4.7 demonstra o desempenho global do classificador. O modelo obteve um mAP@0.5 (*mean Average Precision*) com limiar de IoU de 0,5) de 0,878 para todas as classes. A curva mantém-se próxima ao canto superior direito, o que denota um classificador robusto, capaz de manter altos níveis de precisão mesmo quando exigida uma alta taxa de revocação.

A matriz de confusão normalizada apresentada na Figura 4.8 evidencia o desempenho do modelo YOLOv8 na distinção entre as classes Suspensão-de-areia-e-goma e *Background*. Essa matriz foi construída a partir da comparação entre as detecções realizadas pela YOLOv8 e as anotações reais (*ground truth*) presentes no conjunto de validação. Para cada imagem, o modelo gera caixas delimitadoras (*bounding boxes*), classes previstas e níveis de confiança para os objetos identificados. Em seguida, cada detecção é comparada com as caixas reais correspondentes por meio do critério de IoU (*Intersection over Union*). Quando a classe prevista está correta, a detecção é contabilizada como verdadeiro positivo; caso contrário, é registrada como erro de classificação, falso positivo ou falso negativo. A partir da soma dessas ocorrências em todas as imagens avaliadas, é construído a matriz de confusão, na qual as colunas representam as classes reais (*True*) e as linhas as classes previstas (*Predicted*). Posteriormente, os valores são normalizados entre 0 e 1. As linhas representam as classes previstas pelo modelo, enquanto as colunas correspondem às classes verdadeiras (*ground truth*). Para a classe Suspensão-de-areia-e-goma, verifica-se que 83% dos pixels foram corretamente identificados.

Figura 4.8 - Matriz de confusão normalizada do treinamento YOLOv8.




Fonte: Elaborado pelo autor.

Esses resultados indicam que, embora o modelo apresente alta precisão na detecção do fundo, ainda há uma taxa moderada de falsos negativos na identificação da suspensão, possivelmente associada a regiões com menor contraste, sobreposição de partículas ou variações de iluminação.

A comparação visual apresentada na Figura 4.9 evidencia a capacidade do modelo YOLOv8 na detecção da suspensão. A análise demonstra a predição do modelo que o sistema é capaz de localizar e delimitar de maneira consistente as regiões correspondentes à suspensão por meio de *bounding boxes*, discriminando-as adequadamente do fundo e de outros elementos presentes na cena. A cena apresenta diferentes trechos da peneira em forma de mosaico que foi aplicado nas imagens de treino na etapa de formação do banco de dados.

Figura 4.9- Detecção através de *bounding boxes* (caixas azuis) do modelo YOLOv8 durante o treino do modelo.



Fonte: Elaborado pelo autor.

4.2 Comparação entre os parâmetros estimados (Área Preenchida e Velocidade de Escoamento) pelos modelos e as referências experimentais

Nesta seção, são apresentados os resultados da Área Preenchida (AP) e Velocidade Média (V_M) estimadas por visão computacional em comparação com os valores de referência obtidos experimentalmente para diferentes condições operacionais (combinações de RPM e vazão) para os modelos utilizando U-Net e YOLOv8.

4.2.1 Área preenchida e Velocidade Média estimadas pelo software utilizando U-Net em Matlab

O software desenvolvido em ambiente Matlab baseado na segmentação utilizando a rede neural U-Net permitiu estimar os parâmetros operacionais de área da tela preenchida por cascalhos estimada pelo modelo (AP_M) e velocidade média de escoamento dos sólidos da suspensão estimada pelo modelo (V_M) e comparar esses valores com as referências experimentais para verificar a eficácia do modelo.

A referência da Área Preenchida considerada é o próprio *groundtruth* construído com as imagens de treino, consideradas o gabarito, afinal as anotações realizadas foram feitas com precisão, para que o treino do modelo seja mais fiel da realidade possível. O parâmetro de Velocidade Média estimada, foi comparado com a Velocidade Seccional (VS) sendo um valor de referência experimental para comparação.

Após o cálculo de todos os parâmetros desejados para cada condição operacional e vazão, o erro relativo absoluto (ER_A) e o erro relativo absoluto médio (ER_{AM}) foram avaliados. Essas métricas comparam a área média preenchida (AP_M) estimada pelo modelo com a área preenchida esperada (AP_E), bem como a velocidade média (V_M) estimada pelo modelo com a velocidade seccional (VS). Os valores correspondentes estão compilados nas

Tabela 4.2 e Tabela 4.3.

Os resultados obtidos indicam que o modelo U-Net foi capaz de estimar de forma consistente as variações da área ocupada pela suspensão ao longo do tempo para as diferentes condições operacionais testadas. Em geral, observou-se que os valores médios de AP estimados pelo modelo apresentaram boa concordância com os valores experimentais utilizados como referência.

Particularmente para a operação a 1200 RPM e vazão de 30 m³/h, ficou evidente que, em condições em que a taxa de alimentação se aproxima do limite operacional da tela, a região da praia reflete uma quantidade significativa de luz e é visivelmente perturbada pela agitação

dos motores vibratórios. Isso dificulta a capacidade da U-Net de detectar a suspensão com precisão. Tal comportamento destaca a sensibilidade do modelo à densidade de cobertura da tela, indicando a necessidade de um treinamento mais robusto da rede usando dados dessas condições operacionais.

Em relação à velocidade média de escoamento estimada pelo modelo, o comportamento foi considerado satisfatório, dada a coerência e consistência dos resultados. Observou-se um aumento na velocidade média de escoamento em resposta ao aumento da taxa de alimentação. Em alguns casos, especialmente a 1800 RPM e 30 m³/h, a câmera apresentou uma mudança na direção de filmagem devido à vibração da tela, o que impactou negativamente os algoritmos de estimativa de área e velocidade, devido à sensibilidade do método ao cálculo de deslocamento baseado em pixel do material sólido.

Tabela 4.2 - Resultados de área preenchida estimada e erro relativo utilizando U-Net.

Operação	Vazão (m³/h)	AP_M (%)	AP_E (%)	ER_A (%)	ER_{AM} (%)
1200	20	45,31	44,41	2,02	8,52
	30	83,93	70,38	19,25	
	40	67,25	70,26	4,28	
1800	20	12,44	18,97	34,42	24,42
	30	14,13	17,02	16,98	
	40	16,79	23,27	27,85	

Fonte: Elaborado pelo autor.

Tabela 4.3 - Resultados de velocidade média estimada e erro relativo utilizando U-Net.

Operação	Vazão (m³/h)	V_M (cm/s)	VS (cm/s)	ER_A (%)	ER_{AM} (%)
1200	20	1,66	1,60	3,75	10,19
	30	3,77	3,18	18,32	
	40	3,45	3,18	8,49	
1800	20	4,43	5,10	13,14	13,69
	30	9,62	7,63	26,08	
	40	9,36	9,19	1,85	

Fonte: Elaborado pelo autor.

De modo geral, os resultados indicam que o modelo utilizando U-Net, integrado ao software desenvolvido, constitui uma ferramenta eficaz para a estimativa automática e não invasiva de parâmetros operacionais relevantes em peneiras vibratórias industriais, permitindo

o monitoramento contínuo da área preenchida e da velocidade de escoamento a partir de imagens de vídeo.


4.2.1.1 Software e interface gráfica de apoio ao operador desenvolvidos em Matlab

O software desenvolvido em Matlab utilizando U-Net dedicado para o monitoramento do processo, integra todas as etapas de aquisição de vídeo, segmentação, cálculo de área preenchida, estimativa de velocidade e exibição gráfica dos resultados em tempo real. A interface foi projetada para ser utilizada por operadores sem conhecimento aprofundado em visão computacional, tornando o sistema aplicável em ambiente industrial.

Nas Figura 4.10 e


Figura 4.11, pode-se observar a interface do operador, com exemplos dos gráficos dinâmicos em tempo real de Área Preenchida e Velocidade ao longo do tempo, além da indicação de limites experimentais de referência mínimo e máximo (linhas vermelhas). Além da visualização da detecção de suspensão realizada pela rede U-Net (em vermelho) e do escoamento da suspensão nos quadros de vídeo analisados.

Figura 4.10 - Interface de software de visão computacional em Matlab exibindo análise de vídeo em tempo real para operação em 1200RPM e $20 \text{ m}^3/\text{h}$.



Fonte: Elaborado pelo autor.

Figura 4.11 - Interface de software de visão computacional em Matlab exibindo análise de vídeo em tempo real para operação em 1800RPM e 40 m³/h.



Fonte: Elaborado pelo autor.

A partir do sistema implementado, qualquer evento anômalo pode ser observado durante o monitoramento do processo pode ser visualizada em tempo real a partir da interface, sendo de extrema relevância ao responsável pelo processo, fornecendo informações valiosas e diminuindo o tempo de resposta sobre o sistema.

4.2.1.2 Software para a determinação da morfologia dos sólidos na peneira desenvolvido em Matlab


Foi implementado também um aplicativo para a determinação da morfologia dos sólidos na peneira através de descritores morfológicos do objeto de interesse, como a área média dos objetos, circularidade, excentricidade, solidez, e *aspect ratio* (razão entre a largura e altura). A razão de implementar essas estimativas de morfologia dos sólidos é extrair informações adicionais e caracterizá-las por métricas quantitativas, possibilitando uma interpretação com mais detalhes do estado do material sobre a peneira e podem estar relacionados a fenômenos relevantes do processo.

Um exemplo da análise da excentricidade e da razão de aspecto pode revelar padrões de alongamento dos sólidos, podendo estar associados à cascalhos de desmoronamento, devido a serem mais alongados. De forma complementar, métricas como circularidade e solidez podem indicar irregularidades geométricas (partículas alongadas ou arredondadas), sobreposição entre partículas ou alterações no formato decorrentes das condições operacionais.

Apresenta-se na Figura 4.12 um exemplo de tal aplicação, onde é possível observar no canto direito superior as métricas de morfologia sendo calculadas a cada frame, além de gerar um relatório com os valores de cada métrica calculada.

Apesar da metodologia não ter sido validada, a implementação é valiosa para futuros trabalhos, uma vez que é um indicativo de mudanças de comportamento dos sólidos, sendo importante para análises da morfologia dos sólidos.

Figura 4.12 - Interface de software de visão computacional em Matlab incluindo a análise de morfologia do vídeo em tempo real para operação em 1200RPM e 20 m³/h.



Fonte: Elaborado pelo autor.

4.2.2 Área preenchida e Velocidade Média estimadas pelo software desenvolvido com YOLOv8 no ambiente Python

De forma análoga à versão do software em Matlab, foram estimados os parâmetros de interesse de área da tela preenchida por cascalhos estimada pelo modelo (AP_M) e velocidade

média de escoamento dos sólidos da suspensão estimada pelo modelo (V_M) utilizando o modelo de rede neural YOLOv8 em ambiente Python.

O erro relativo absoluto (ER_A) foi calculado para ambas as operações (Tabela 4.4), comparando-se o valor médio final da porcentagem de área preenchida obtido pelo modelo (AP_M) com a área preenchida esperada (AP_E). Em seguida, calculou-se o erro relativo absoluto médio para cada operação (ER_{AM}). De modo equivalente, a Tabela 4.5 apresenta os resultados de velocidade obtidos pelo modelo (V_M) e a VS, de maneira análoga, comparando-as, calculando-se o ER_A e o ER_{AM} .

A análise dos resultados revelou que, para a rotação de 1200 RPM, especialmente nas vazões de alimentação de 30 m³/h e 40 m³/h, a tela operava próxima da condição de saturação, apresentando percentuais de área preenchida superiores a 70%. Essa elevada ocupação da tela tende a reduzir o contraste entre as classes detectadas pela rede, dificultando a segmentação e afetando a precisão da inferência. Adicionalmente, a técnica empregada para mensurar a vazão mássica na região de coleta apresentou limitações operacionais. O uso de um tubo coletor manual, acoplado na saída da peneira, pode ter introduzido oscilações na coleta e interferido na distribuição do escoamento, o que possivelmente explica a semelhança entre os valores de vazão mássica na região de coleta nas condições de vazão de alimentação de 30 e 40 m³/h na operação de 1200 RPM.

Tabela 4.4 - Resultados de área preenchida estimada e erro relativo utilizando YOLOv8.

Operação	Vazão (m ³ /h)	AP _M (%)	AP _E (%)	ER _A (%)	ER _{AM} (%)
1200	20	49,32	44,41	11,06	7,76
	30	75,31	70,38	7,00	
	40	73,92	70,26	5,21	
1800	20	11,16	18,97	41,17	15,53
	30	16,12	17,02	5,29	
	40	23,24	23,27	0,13	

Fonte: Elaborado pelo autor.

Tabela 4.5 - Resultados de área preenchida estimada e erro relativo utilizando YOLOv8.

Operação	Vazão (m ³ /h)	V _M (cm/s)	VS (cm/s)	ER _A (%)	ER _{AM} (%)
1200	20	1,50	1,60	6,25	15,13
	30	2,72	3,18	14,56	
	40	2,40	3,18	24,53	

1800	20	5,5	5,1	7.84	5,90
	30	6,97	7,63	8.65	
	40	9,30	9,19	1,20	

Fonte: Elaborado pelo autor.

Outro ponto crítico detectado refere-se à estimativa da área utilizada para o cálculo de Velocidade Seccional. A ausência de utilização de um sensor capaz de medir a altura efetiva da lâmina de fluido em escoamento forçou a adoção de uma altura fixa de 0,5 cm para todas as operações. Além disso, assumiu-se que toda a largura da extremidade da peneira estava sendo atravessada no escoamento de cascalhos, o que pode superestimar a seção de saída transversal ao escoamento real em operações com menor dispersão lateral dos sólidos, como as operações com 1800 RPM. Tais simplificações impactam diretamente na exatidão da velocidade teórica calculada.

Apesar das limitações experimentais, os resultados obtidos demonstram o potencial da abordagem proposta. A estimativa da velocidade de escoamento da suspensão, quando comparada à Velocidade Seccional, apresentou boa concordância em diversas condições operacionais, especialmente nas situações em que a tela não estava saturada, como nas vazões de 20 m³/h e nas operações com rotação de 1800 RPM. Nessas condições, observou-se maior precisão na detecção das bordas dos objetos e melhor separação entre as classes, o que contribuiu para a estabilidade das estimativas de velocidade. Esse comportamento corrobora a sensibilidade do modelo à densidade de preenchimento da tela, reforçando a relevância de aplicar técnicas de aumento de dados e treinamento robusto.

Além disso, o software foi capaz de capturar uma tendência física coerente com o processo: a velocidade média de escoamento estimada aumentou com a elevação da vazão de alimentação em ambas as rotações, refletindo adequadamente o comportamento esperado do sistema. A comparação entre as duas rotações também indicou que a operação a 1800 RPM proporcionou escoamentos mais rápidos e visualmente mais distribuídos, o que pode ser associado ao maior nível de agitação e dispersão lateral promovido pela vibração mais intensa.

4.2.2.1 Software e interface gráfica de apoio ao operador desenvolvidos em Python


A implementação do software em Python, de forma semelhante à versão em Matlab, foi concebida contemplando, em um único ambiente, as etapas de aquisição e processamento de vídeo, segmentação automática da suspensão, cálculo da área preenchida, estimativa da velocidade de escoamento superficial e apresentação gráfica dos resultados ao operador. A

arquitetura do sistema foi estruturada de forma modular, permitindo a execução contínua em tempo real ou a análise posterior de vídeos gravados.

A interface gráfica foi desenvolvida com foco em usabilidade e interpretação simples dos resultados. Além dos gráficos quantitativos, a interface também exibe, em tempo real, o resultado da segmentação realizada pelo modelo YOLOv8, destacando as regiões correspondentes à suspensão por meio de *bounding boxes* verdes sobrepostas aos quadros de vídeo analisados. Essa visualização simultânea dos dados numéricos e das predições visuais facilita a interpretação do comportamento do escoamento e auxilia na tomada de decisão operacional. Na Figura 4.13 e na Figura 4.14 são apresentados os resultados do software ao longo do processamento.


O software exibe as medições feitas dos parâmetros, além da área preenchida esperada e VS calculadas, além da média final calculada, sendo também útil para detectar possíveis anomalias durante o processo de monitoramento de separação sólido-líquido nas peneiras.

Figura 4.13 - Interface de software de visão computacional em Python exibindo análise de vídeo em tempo real para operação em 1200RPM e 20 m³/h.



Fonte: Elaborado pelo autor.

Figura 4.14 - Interface de software de visão computacional em Python exibindo análise de vídeo em tempo real para operação em 1800RPM e 40 m³/h.



Fonte: Elaborado pelo autor.


4.2.2.2 Software para a determinação da morfologia dos sólidos na peneira desenvolvido em Python

A implementação do cálculo de descritores morfológicos também foi realizada no ambiente Python, para análise dos sólidos na peneira. Apesar da segmentação ser realizada por caixas delimitadoras, pode-se calcular somente descritores como: área, perímetro, eixo maior, eixo menor, diâmetro equivalente e excentricidade. Na Figura 4.15, observa-se a interface com

os parâmetros de Área Preenchida, Velocidade, além do relatório final com as métricas da morfologia.

Essa análise, apesar de não ter sido validada, futuramente pode oferecer ao operador mais uma ferramenta de apoio e observação do objeto de interesse e identificação de padrões geométrico dos sólidos ou identificação de objetos anômalos.

Figura 4.15 - Interface gráfica de exibição ao operador do relatório de morfologia em uma operação de 1800RPM e 40 m³/h.



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

Fonte: Elaborado pelo autor.

O objetivo dessa implementação foi fornecer ferramentas para ampliar a análise dos cascalhos que retornam do poço durante a perfuração, fornecendo uma visão mais rica e multidimensional do comportamento do objeto de interesse. Ainda que a validação direta desses parâmetros morfológicos não tenha sido o foco principal deste trabalho, sua implementação abre caminho para estudos futuros voltados à correlação entre morfologia do escoamento e objetos anômalos durante o processo.

CAPÍTULO 5. CONCLUSÕES FINAIS

O presente trabalho foi capaz de desenvolver e avaliar uma metodologia baseada em visão computacional e aprendizado profundo para o monitoramento automático de parâmetros operacionais relevantes em peneiras vibratórias industriais, com foco na estimativa da área da tela preenchida por cascalhos (AP) e a velocidade média de escoamento dos sólidos da suspensão (VM), bem como na extração de características morfológicas dos cascalhos que retornam do poço durante o processo de perfuração.

No âmbito computacional, foram implementadas duas abordagens distintas de segmentação baseadas em aprendizado profundo: uma rede U-Net treinada em MATLAB para segmentação semântica e uma rede YOLOv8 treinada em Python para detecção/segmentação baseada em *bounding boxes*. Ambas as metodologias demonstraram capacidade satisfatória de identificar as regiões correspondentes aos sólidos presentes na peneira a partir da análise dos vídeos analisados, distinguindo-as adequadamente do fundo e de outros elementos presentes na cena.

De acordo com os resultados, a rede U-Net apresentou bom desempenho na segmentação detalhada das regiões de interesse, permitindo a geração de máscaras binárias robustas, a partir das quais foi possível calcular a AP com base na razão entre a área segmentada e a área total do frame analisado. A estimativa da VM foi realizada por meio do rastreamento do deslocamento médio do objeto de interesse entre pares consecutivos de frames. Os resultados obtidos indicaram que as estimativas de AP e VM apresentaram comportamento coerente com os valores das referências experimentais, tanto qualitativa quanto quantitativamente, para as diferentes condições operacionais avaliadas.

Paralelamente, o modelo YOLOv8 mostrou-se eficaz para a detecção e delimitação das regiões de suspensão por meio de bounding boxes, alcançando desempenho satisfatório segundo as métricas padrão de avaliação de modelos de detecção, como Precisão, Revocação e mAP (*mean Average Precision*). A análise das curvas Precisão–Revocação e dos demais indicadores de validação demonstrou que o modelo foi capaz de equilibrar adequadamente a minimização de falsos positivos e falsos negativos, sendo viável para aplicação em monitoramento em tempo real.

Além da segmentação e das estimativas de AP e VM, foi incorporada ao sistema uma análise morfológica dos cascalhos que retornam do poço durante o processo de perfuração, incluindo métricas como circularidade, excentricidade, solidez e razão de aspecto. Embora essa análise não tenha sido formalmente validada neste trabalho, sua implementação permitiu a

extração de informações adicionais sobre a estrutura e o comportamento geométrico da suspensão sobre a peneira, abrindo caminho para investigações futuras mais aprofundadas.

Entretanto, é necessário pontuar as limitações identificadas durante o estudo. A precisão dos modelos é sensível a variações extremas de iluminação e à presença de vapores que podem ocluir a superfície da suspensão, dificultando a detecção pelo modelo. Além disso, a validação das estimativas de velocidade e área dependeu de referências experimentais baseadas em premissas simplificadoras, como a altura fixa da lâmina de fluido, devido à ausência de sensoriamento direto para esses parâmetros no aparato experimental utilizado. Tais fatores indicam que, embora os modelos sejam robustos, a sua precisão absoluta está vinculada à qualidade da aquisição de dados e à calibração com sensores físicos complementares, além de demandar validações adicionais em condições industriais reais, visto que os experimentos foram conduzidos em ambiente controlado.

Do ponto de vista do desenvolvimento de aplicativos, os softwares desenvolvidos em MATLAB (baseado em U-Net) e em Python (baseado em YOLOv8) demonstraram potencial como ferramentas não invasivas para monitoramento contínuo do processo. As interfaces gráficas implementadas foram projetadas para facilitar a interpretação dos resultados por operadores industriais, integrando visualização em tempo real das segmentações com gráficos dinâmicos de AP e VM, além de indicadores de referência experimental.

Do ponto de vista prático, a metodologia proposta apresenta elevada aplicabilidade industrial, podendo ser empregada em sistemas de supervisão para acompanhamento contínuo do desempenho das peneiras, identificação precoce de ineficiências operacionais e apoio à tomada de decisão por operadores e engenheiros. Além disso, como perspectiva futura, destaca-se o potencial de integração desses modelos com estratégias de controle de processos, permitindo ajustes automáticos em variáveis operacionais, como inclinação da peneira, frequência de vibração e vazão de alimentação, com base em indicadores extraídos em tempo real. Tal avanço pode conduzir ao desenvolvimento de sistemas inteligentes, autônomos e conectados, alinhados aos princípios da Indústria 4.0 e à crescente demanda por operações mais eficientes, seguras e sustentáveis.

Em síntese, este trabalho contribuiu para o avanço do uso de técnicas de visão computacional e aprendizado profundo no contexto de peneiramento vibratório industrial, demonstrando que é possível estimar parâmetros operacionais relevantes de forma automática, contínua e não invasiva, a partir de imagens de vídeo. Os resultados obtidos indicam que a metodologia proposta possui potencial para apoiar a tomada de decisão operacional, otimizar o desempenho do equipamento e reduzir a dependência de medições manuais ou indiretas.

CAPÍTULO 6. SUGESTÕES PARA TRABALHOS FUTUROS

Com base nos resultados obtidos e nas limitações identificadas ao longo do desenvolvimento deste trabalho, são sugeridas as seguintes direções para pesquisas futuras:

- Aprimoramento do Sistema de Aquisição de Dados: Implementar sistemas de iluminação controlada e estabilização mecânica da câmera para minimizar ruídos visuais causados pela vibração e reflexos;
- Adoção de ferramentas mais rígidas para produção dos parâmetros comparativos, como o sensoramento de nível e do comprimento da peneira efetivamente atravessado pelo material coletado;
- Realizar experimentos específicos para correlacionar quantitativamente as métricas morfológicas extraídas (circularidade, excentricidade, solidez, razão de aspecto, distribuição de tamanhos) com propriedades físicas da suspensão, como granulometria, reologia e eficiência de separação da peneira;
- Desenvolvimento de um sistema de alerta inteligente: Integrar algoritmos de detecção de anomalias baseados em séries temporais para identificar desvios significativos na AP, VM ou morfologia da suspensão, emitindo alertas automáticos ao operador;
- Monitoramento em escala industrial e validação de longo prazo: Implantar o sistema em uma planta industrial real por períodos prolongados, avaliando sua estabilidade, confiabilidade e impacto na operação ao longo do tempo;
- Uso de Modelos Multimodais: implementar arquiteturas de aprendizado profundo multimodais, capazes de processar e cruzar, em tempo real, os dados de visão computacional (como Área Preenchida e Velocidade Média) com dados físicos oriundos de sensores do sistema de perfuração em tempo real (taxa de penetração, torque e rotação da broca). A fusão de dados visuais com dados de acelerômetros (força-G e vibração), sensores de fluxo e dados reológicos enriqueceria o aprendizado da rede, gerando modelos capazes de correlacionar alterações na morfologia dos cascalhos diretamente com as respostas físicas da formação e do equipamento;
- Predição de Falhas e Manutenção Preditiva: Com a consolidação de um banco de dados temporal robusto das operações nominais da peneira, os algoritmos podem evoluir da simples detecção para o diagnóstico preditivo. Alterações sutis nos padrões de escoamento, acúmulo assimétrico de material ou variações anômalas na velocidade de deslocamento dos sólidos podem ser utilizadas para treinar modelos preditivos capazes de antecipar fenômenos indesejáveis, como o cegamento (*blinding*) da tela, rasgos e danos na malha ou

desgastes nos motovibradores. Isso transformaria a abordagem de manutenção corretiva do sistema de controle de sólidos em uma manutenção estritamente proativa;

- Desenvolvimento de um Gêmeo Digital (*Digital Twin*): A culminação da integração entre os modelos visuais, os dados multimodais e os algoritmos de predição possibilitariam a criação de um *digital twin* da peneira vibratória. Esse modelo virtual espelharia o comportamento em tempo real do equipamento físico, possibilitando simular diferentes cenários operacionais, testar mudanças na inclinação ou o aumento da vazão da bomba e prever como a suspensão se comportará antes mesmo de a ação ser executada no poço. Este recurso permitiria que o processo operasse sempre em seu ponto ótimo operacional;
- Investigar outros modelos neurais.

CAPÍTULO 7. REFERÊNCIAS BIBLIOGRÁFICAS

AADNØY, B. S.; LOOYEH, R. **Petroleum Rock Mechanics: Drilling Operations and Well Design**, Oxford: Gulf Professional, 2011.

AMERICAN PETROLEUM INSTITUTE (API). 5edn RP 13C – Recommended Practice on Drilling Fluid Processing Systems Evaluation. Washington, DC: American Petroleum Institute, 2014.

ASME SHALE SHAKER COMMITTEE. **Drilling Fluids Processing Handbook**. Burlington: Gulf Professional Publishing, 2005.

BADIS, C., SOUZA, W., YASIR, M. A.; SABHARWAL, P. **Machine Learning/Artificial Intelligence Driven Computer Vision for Cuttings Analysis Under Drilling and Completions**. In: SPE EASTERN EUROPE SUBSURFACE CONFERENCE. Ucrânia. Society of Petroleum Engineers, 2021. Paper Number: SPE-208509-MS.

BARBOSA, V. P. **Avaliação de Fatores Operacionais em Processo de Peneiramento Vibratório Aplicado à Separação Sólido-Líquido Com Auxílio de Técnicas de Análise de Imagem**. Dissertação (Mestrado em Engenharia Química) – Universidade Federal de Uberlândia. Uberlândia, p. 98, 2018.

BHATT, D.; PATEL, C.; TALSANIA, H.; PATEL, J.; VAGHELA, R.; PANDYA, S.; MODI, K.; GHAYVAT, H. **CNN variants for computer vision: history, architecture, application, challenges and future scope**. Electronics, v. 10, n. 20, p. 2470, 2021.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.

BOURGOYNE JUNIOR, A. T.; MILLHEIM, K. K.; CHENEVERT, M. E.; YOUNG JUNIOR, F. S. **Applied Drilling Engineering**. Richardson: Society of Petroleum Engineers, 1986.

BRIDGES, S.; ROBINSON, L. **A practical handbook for drilling fluids processing**. Houston, TX: Gulf Professional Publishing, 2020. 793 p.

CAENN, R., CHILLINGAR, G. V. **Drilling Fluids: State Of The Art**, Journal of Petroleum Science and Engineering, v.14, 1996.

CAENN, R.; DARLEY, H. CH.; GRAY, G. R. **Fluidos de Perfuração e Complementação**. 1. Ed. Rio de Janeiro. Elsevier, 2014.

CAENN, R.; DARLEY, H. CH.; GRAY, G. R. **Composition and Properties of Drilling and Completion Fluids**. Seventh Edi. Elsevier, Cambridge, United States, 2017.

CALÇADA, L.A., NETO, DUQUE, O.A., MAGALHÃES, S.C., SCHEID, C.M., BORGES FILHO, M.N., WALDMANN, A.T.A. **Evaluation of Suspension Flow and Particulate**

Materials for Control of Fluid Losses in Drilling Operation. Journal of Petroleum Science and Engineering, v 131, p. 1 -10, 2015.

CHARLES, J. P.; SAYLE, W. S. **Environmental Aspects of Drilling Fluids.** In: SPE International Conference on Health, Safety, and Environment in Oil and Gas Exploration and Production. Society of Petroleum Engineers, 2010.

CHO, H.; SHAH, S. N.; OSISANYA, S. O. **A Three-Segment Hydraulic Model for Cuttings Transport in Horizontal and Deviated Wells.** SPE Journal, Richardson, TX, v. 6, n. 2, p. 168-175, jun. 2001. (SPE-72495-PA).

DARLEY, H. C.; GRAY, G. R. **Composition and Properties of Drilling and Completion Fluids.** Gulf Professional Publishing, Texas, 1988.

DORRY, K.E. **Effect of Constant-G Control on Shale Shaker Performance.** American Association Of Drilling Engineers Fluids Conference And Exhibition, Houston, Texas, Estados Unidos, 2010.

DOVETON, John H. **Geologic Log Interpretation.** Tulsa: Society of Economic Paleontologists and Mineralogists, 1994.

ELLIS, D. V.; SINGER, J. M. **Well Logging for Earth Scientists.** 2. ed. Dordrecht: Springer, 2007.

FAGUNDES, T. B. **Caracterização de cascalhos de perfuração de poços de petróleo por técnicas analíticas instrumentais.** Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Escola Politécnica da Universidade de São Paulo. São Paulo, p. 223, 2018.

FANCHI, J. R. **Petroleum Engineering Handbook: Vol. II. Drilling engineering.** Richardson, TX: Society of Petroleum Engineers, 2010.

FERRAZ, A. D. **Corrosão em Sistemas de Perfuração: Efeito do pH e de Contaminantes.** Escola de Química, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2014.

FILHO, O. M.; NETO H. V. **Processamento Digital de Imagens.** Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

GLOROT, X.; BENGIO, Y. **Understanding the difficulty of training deep feedforward neural networks.** Proceedings Of The Thirteenth International Conference On Artificial Intelligence And Statistics, 2010, Sardinia. Proceedings... Sardinia: JMLR, 2010. p. 249-256.

GN Separation, 2026. GN Dewatering Vibrating Screen. Disponível em: <https://www.gnsolidsamerica.com/dewatering-vibrating-screen.html>. Acesso em 10 fevereiro de 2026.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning.** Cambridge: MIT Press, 2016.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 4. ed. New York: Pearson, 2018.

GOLOVANEVSKIY, V.A.; ARSENTYEV, V.A.; BLEKHMAN, I.I.; VASILKOV, V.B.; AZBEL, Y.I.; YAKIMOVA, K.S. **Vibration-induced phenomena in bulk granular materials**. International Journal of Mineral Processing, v. 100, n. 3-4, p. 79-85, 2011. DOI: 10.1016/j.minpro.2011.05.001.

GOSAVI, S; GILROY, J; RUEL, F; HOLT, C. **Field Application of Image Analysis Models to Measure the Drill Cuttings Recovery Rate**. Society of Petroleum Engineers, 2024. p. 1-15. New Orleans, Louisiana, USA. New Orleans: Paper Number: SPE-220985-MS.

GROSSI, C. D. **Desenvolvimento de um Software de Visão Computacional para Estudo do Escoamento de Cascalhos em Peneira Vibratória**. Dissertação (Mestrado em Engenharia Química) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2020.

GROSSI, C. D.; BARBOSA, V. P.; GEDRAITE, R.; SOUZA, M. B.; SCHEID, C. M.; CALÇADA, L. A.; MELEIRO, L. A. C. **Monitoring of the Drilling Region in Oil Wells Using a Convolutional Neural Network**. Computer Aided Chemical Engineering. v. 52, p. 1353-1358. DOI: 10.1016/B978-0-443-15274-0.50215-8. Elsevier, 2023.

GROSSI, C. D.; HUMMEL, Y. N.; MOURA, E. A.; SCHEID, C. M.; CALÇADA, L. A.; MELEIRO, L. A. C. **Development of Computational Vision Methodologies for Monitoring Cuttings in the Drilling Fluid Treatment System**. BRAZILIAN JOURNAL OF CHEMICAL ENGINEERING, v. R3QA6, p. 0104, 2023.

GUERREIRO, F.S, BARBOSA, V.P., GEDRAITE, R., ATAÍDE, C.H. **Lab Scale Vibrating Screen Study on Operational Variables that Affect the Separation Efficiency**. Materials Science Forum, v. 899, p 124 - 129, 2017

GUIMARÃES, C. D.; ROCHA, L. A. F.; SILVA, E. M. P. **Fluidos de Perfuração: Princípios e Aplicações**. Rio de Janeiro: Petrobras, 2007.

GUIMARÃES, I. B., ROSSI, L. F. S. **Estudo dos Constituintes dos Fluidos de Perfuração: Proposta de uma formulação otimizada e ambientalmente correta**, 4º PDPETRO, Campinas, São Paulo, Outubro, 2007.

HAN, R.; ASHOK, P.; PRYOR, M.; VAN OORT, E. **Real-Time 3D Computer Vision Shape Analysis of Cuttings and Cavings**. In: SPE ANNUAL TECHNICAL CONFERENCE AND EXHIBITION, 2018, Dallas, Texas, EUA. Society of Petroleum Engineers, 2018. Paper Number: SPE-191634-MS.

HARALICK, M.; SHAPIRO, L. G. **Computer and Robot Vision**. Reading: Addison-Wesley, 1992. v. 1.

HINTON, G. E.; SALAKHUDDINOV, R. R. **Reducing the dimensionality of data with neural networks**. Science, v. 313, n. 5786, p. 504-507, 2006.

HOBEROCK, L. L. **A Study of Vibratory Screening of Drilling Fluids**. Journal of Petroleum Technology, v. 32, 1980.

IOFFE, S.; SZEGEDY, C. **Batch normalization: Accelerating deep network training by reducing internal covariate shift**. INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 2015. Proceedings... PMLR, 2015. p. 448-456.

ISABONA, J.; IMOIZE, A. L.; OJO, S.; KARUNWI, O.; KIM, Y.; LEE, C.-C.; LI, C.-T. **Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments**. Applied Sciences, v. 12, n. 11, p. 5713, 2022.

JOCHER, G.; CHAURASIA, A.; QIU, J. **Ultralytics YOLOv8**. GitHub, 2023. Disponível em: <https://docs.ultralytics.com/models/yolov8/>. Acessado em 10 fevereiro de 2026.

KARIMI, M. **Drill-cuttings analysis for real-time problem diagnosis and drilling performance optimization**. In: SPE ASIA PACIFIC OIL AND GAS CONFERENCE AND EXHIBITION, 2013, Jakarta. Jakarta: SPE, 2013. Paper SPE-165919-MS.

KHAN, S.; YAIRI, T. **A review on the application of deep learning in system health management**. Mechanical Systems and Signal Processing, v. 107, p. 241-265, 2018.

KHANDAL, R. K., TADROS, T. F. **Application of Viscoelastic Measurements to The Investigation of the Swelling of Sodium Montmorillonite Suspensions**. Journal of Colloid Interface Science, v.125, 1988.

KHOJASTEH, P.; AHMADYFARD, A.; TOKHMECHI, B.; MIRMAHDAVI, S. A. **Automatic Detection of Formations Using Images of Oil Well Drilling Cuttings**. Journal of Petroleum Science and Engineering 125, Elsevier, p. 67 - 74, 2015.

KING, R. P. **Modeling and simulation of mineral processing systems**. Oxford: Butterworth-Heinemann, 2001.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. **ImageNet classification with deep convolutional neural networks**. ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 2012, Lake Tahoe. Proceedings... Lake Tahoe: NIPS, 2012. p. 1097-1105.

LAGANIER, Colin; FLETCHER, Liam; KWAN, Elim; WALTERS, Richard; NOCKLES, Victoria. **Efficient SAR Vessel Detection for FPGA-Based On-Satellite Sensing**. *arXiv preprint*, 2025. DOI: 10.48550/arXiv.2507.04842.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. **Gradient-based learning applied to document recognition**. Proceedings of the IEEE, v. 86, n. 11, p. 2278-2324, 1998.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning**. Nature, v. 521, n. 7553, p. 436-444, 2015.

LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. **A survey of convolutional neural networks: analysis, applications, and prospects.** IEEE Transactions on Neural Networks and Learning Systems, 2021.

MACHADO, J. C. V. **Reologia e Escoamento de fluidos - Indústria do petróleo.** Rio de Janeiro: Ed. Interciência, 2002.

MAGALHÃES, S. C. **UMPC: Unidade Móvel de Pesquisa Científica: um sistema desenvolvido para aferições em tempo real das propriedades físico-químicas de fluidos de perfuração.** Dissertação (Mestrado em Engenharia Química) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2015.

MARANA, A. N.; CHIACHIA, G.; GUILHERME, I. R.; PAPA, J. P.; MIURA, K.; FERREIRA, M. V. D.; TORRES, F. **An Intelligent System for Petroleum Well Drilling Cutting Analysis. Artificial Intelligence Systems.** IEEE International Conference on Adaptive and Intelligent Systems, p. 37-42, 2009.

MARTINS, R. A. **Controle Fuzzy Multivariável para correção de Propriedades Físico-químicas de Fluidos de Perfuração.** Dissertação (Mestrado em Engenharia Química) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2024.

MATTA, E. N. **Caracterização das Partículas de Material Sólido nas Correntes de Entrada e Saída do Fluido de Perfuração de Poços de Petróleo Fundamentada em Processamento Digital de Imagens.** Dissertação (Mestrado em Engenharia de Processos Químicos e Bioquímicos) – Escola de Engenharia Mauá do Centro Universitário do Instituto Mauá de Tecnologia, São Caetano do Sul, 2014.

MATTA, E. N.; ASSIS, W. O.; GOMES, M. M.; BARBOSA, V. P.; GEDRAITE, R.; ATAÍDE, C. H. **Contribuição Para o Melhor Aproveitamento de Fluido de Perfuração de Poços de Petróleo: Uma Abordagem Utilizando Processamento de Imagem.** Brazilian Journal of Development, v. 5, n. 4, p. 3645, 2019.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity.** Bulletin of Mathematical Biophysics, v. 5, n. 4, p. 115-133, 1943.

MINSKY, M.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry.** Cambridge: MIT Press, 1969.

MITCHELL, R. F.; MISKA, S. Z. **Fundamentals of Drilling Engineering.** Richardson, TX: Society of Petroleum Engineers, 2011.

MONTES, A. C.; CALLERIO, S.; TURHAN, Ç.; SAFAROV, A.; ASHOK, P.; VAN OORT, E. **Automatic determination of cuttings and cavings properties for hole cleaning and wellbore stability assessment using a laser-based sensor.** *SPE Journal*, v. 29, n. 10, p. 5238–5256, 2024. DOI: 10.2118/217736-PA.

NASCENTES, C. L. **Separação Sólido-fluido de Perfuração em Peneiras Vibratórias**. Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Química, Uberlândia, 2019.

NCSIZ, S.; YILDIRIM, T. A neural network-based model for the optimization of a chemical process. *Computers & Chemical Engineering*, v. 28, n. 6-7, p. 1149-1155, 2004.

NORONHA, M. E. S. **Análise do Comportamento Tixotrópico de Fluidos de Perfuração à Base de Água**. Dissertação (Mestrado em Engenharia de Petróleo) - Universidade Estadual de Campinas, Campinas, 2016.

NORONHA, V. E, **Avaliação de Medidas Reológicas em Viscosímetro Online**. Dissertação (Mestrado em Engenharia Química) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2016.

NWANKPA, C.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. **Activation functions: Comparison of trends in practice and research for deep learning**. arXiv preprint arXiv:1811.03378, 2018.

PEREIRA, M. S. **Aplicação de Secagem por Micro-ondas no Tratamento de Cascalho de Perfuração**. Tese (Doutorado em Engenharia Química) – Universidade Federal de Uberlândia. Minas Gerais, p. 176, 2013.

PETRI, J. I. **Descontaminação de Cascalhos de Perfuração Utilizando um Secador Micro-ondas Semi-industrial em Regime Contínuo**. Tese (Doutorado em Engenharia Química) – Universidade Federal de Uberlândia. Minas Gerais, p. 176, 2017.

RAJA, M. A.; SHAH, Syed N. **Drilling Fluid Technology**. Houston: Gulf Professional Publishing, 2017.

RAJA, V., CHASE, G.G., JONES, B.N., GEEHAN, T. **Computational modeling and Experiments on Shale Shaker Performance**. AAE Fluids Technical Conference and Exhibition, Houston, Texas, 2012.

RAVI, N.; GABEUR, V.; HU, Y.T.; HU, R.; RYALI, C.; MA, T.; KHEDR, H.; RÄDLE, R.; ROLLAND, C.; GUSTAFSON, L.; MINTUN, E.; PAN, J.; ALWALA, K. V.; CARION, N.; WU, C.-Y.; GIRSHICK, R.; DOLLÁR, P.; FEICHTENHOFER, C. **SAM 2: Segment Anything in Images and Videos**. arXiv Preprint, 2024.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. **You only look once: Unified, real-time object detection**. Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition, 2016, Las Vegas. Proceedings. Las Vegas: IEEE, 2016. p. 779-788.

REDMON, J.; FARHADI, A. **YOLO9000: Better, faster, stronger**. Proceedings Of The Ieee Conference On Computer Vision And Pattern Recognition, 2017. Proceedings. IEEE, 2017. p. 7263-7271.

REDMON, J.; FARHADI, A. **YOLOv3: An incremental improvement**. arXiv preprint arXiv:1804.02767, 2018.

RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-Net: Convolutional networks for biomedical image segmentation**. International Conference On Medical Image Computing And Computer-Assisted Intervention, 2015, Munich. Proceedings. Munich: Springer, 2015. p. 234-241.

ROSENBLATT, F. **The perceptron: a probabilistic model for information storage and organization in the brain**. Psychological Review, v. 65, n. 6, p. 386-408, 1958.

RUGGIERO, M.; MELEDETH, A.; DE SMEDT, F.; KUCS, R.; RIPPERGER, G.; COMOTTI, S.; COCKRAM, L.; COLOMBO, I. **Automated and Unmanned Shale Shaker Performance and Borehole Instability Monitoring Using Computer Vision and Artificial Intelligence**. ADIPEC, 2024, Abu Dhabi. Society of Petroleum Engineers, 2024. Paper Number: SPE-222109-MS.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating errors**. Nature, v. 323, n. 6088, p. 533-536, 1986.

SAINATH, T. N.; KINGSBURY, B.; MOHAMED, A.-R.; DAHL, G. E.; SAON, G.; SOLTAU, H.; BERAN, T.; ARAVKIN, A. Y.; RAMABHADHAN, B. **Improvements to deep convolutional neural networks for LVCSR**. 2013 IEEE WORKSHOP ON AUTOMATIC SPEECH RECOGNITION AND UNDERSTANDING, 2013. Proceedings... IEEE, 2013. p. 315-320.

SCHLUMBERGER. **Log Interpretation Principles and Applications**. Houston: Schlumberger Educational Services, 2004.

SCOTT, E.L. **Automatic Shaker Control**. IADC/SPE Drilling Conference, Miami, Florida, Estados Unidos, 2006.

SERAPIÃO, A. B. S.; MENDES, J. R. P.; MIURA, K. **Sistema de Visão Computacional para Detecção de Cascalho de Perfuração em Poços de Petróleo**. Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás (PDPetro), Florianópolis - SC, 2011.

SILVA, R. M. **Análise de imagem aplicada em processo de peneiramento vibratório**. Trabalho de Conclusão de Curso (Graduação em Engenharia Química) – Universidade Federal de Uberlândia, Uberlândia, p. 57, 2017.

SINGH, H.; LI, C.; CHENG, P.; WANG, X.; HAO, G.; LIU, Q. **Automated real-time formation evaluation from cuttings and drilling data analysis: State of the art**. Journal of Natural Gas Science and Engineering, v. 108, 104836, 2023.

SOCIETY OF PETROLEUM ENGINEERS. **Digital oilfield concepts and applications**. Richardson: SPE, 2014.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis, and Machine Vision**. 4. ed. Boston: Cengage Learning, 2015.

SOUZA, J.M. **Estudo da Sedimentação de Sólidos Adensantes Baseado na Técnica de Monitoramento da Pressão Hidrostática**. Dissertação (Mestrado em Engenharia Química) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2024.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. **Dropout: a simple way to prevent neural networks from overfitting**. Journal of Machine Learning Research, v. 15, n. 1, p. 1929-1958, 2014.

SUN, T.; WU, B.; ZHANG, H.; HAN, Y.; LIU, H.; ZHANG, Y. **Discrete element simulation of particle flow and separation in a vibrating screen with variable rectangular hole screen**. *Powder Technology*, v. 434, 2024. DOI: 10.1016/j.powtec.2023. 119305.

SVENDSEN, K. E.; KRISTIANSEN, T. G.; MARTIN, J.; ASKØ, A.; BJØRLO, J.; KHOSRAVANI, R.; HOLT, C.; RUEL, F. **Automated Computer Vision System for Real-Time Detection of Drilled Cuttings and Cavings**. In: SPE/IADC INTERNATIONAL DRILLING CONFERENCE AND EXHIBITION, 2025, Stavanger, Noruega. Society of Petroleum Engineers, 2025.

TERVEN, J. R.; CÓRDOVA-ESPARZA, D. M.; ROMERO-GONZÁLEZ, J. A. **A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS**. Machine Learning and Knowledge Extraction, v. 5, n. 4, p. 1680-1716, 2023.

THOMAS, J. E. **Fundamentos de Engenharia de Petróleo**. 2. ed. Rio de Janeiro: Interciência, 2001.

ULTRALYTICS. **Arquitetura de rede neural com perceptrons e princípios básicos da visão computacional 2023**. Disponível em: <https://www.ultralytics.com/pt/blog/perceptrons-and-neural-networks-basic-principles-of-computer-vision>. Acessado em: 10 de fevereiro de 2026.

VAN OORT, E. **On the Physical and Chemical Stability of Shales**. Journal of Petroleum Science and Engineering, Amsterdam, v. 38, n. 3-4, p. 213-235, 2003.

WANG, W.; HOU, Y.; WU, X.; JIANG, R.; LI, H. **Solid-liquid separation state control system for shale shaker based on computer vision**. Journal of Petroleum Science and Engineering, v. 245, p. 3303-3328, 2024.

WEIMER, D.; SCHOLZ-REITER, B.; SHPITALNI, M. **Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection**. CIRP Annals, v. 65, n. 1, p. 417-420, 2016.

ZHANG, X.; KOU, Y.; ZHANG, X.; SHI, Q.; HU, Y.; WU, H.; LIU, S.; ZHENG, P. **Hybrid digital twins for smart manufacturing: Architectures, fusion paradigm, and implementation challenges**. Journal of Manufacturing Systems, v. 85, p. 51-71. ISSN 0278-6125. DOI: 10.1016/j.jmsy.2025.12.029, 2026.

ZHAO, X.; WANG, L.; ZHANG, Y.; HAN, X.; DEVECI, M.; PARMAR, M. **A review of convolutional neural networks in computer vision**. Artificial Intelligence Review, v. 57, n. 99, 2024. DOI: 10.1007/s10462-024-10721-6.

ANEXO 1. DECLARAÇÃO DE USO CONSCIENTE DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL

Pelo presente termo, eu, ANDRÉ CHRISTIANO CLARO MIGUEL, declaro que, durante o desenvolvimento de minha Dissertação, não utilizei de forma inadequada ferramentas de Inteligência Artificial para a geração de textos, códigos de computador, referências falsas ou em quaisquer outras partes do meu trabalho.

Declaro, ainda, que não cometi plágio nem reproduzi indevidamente conteúdos de terceiros.

Adicionalmente, afirmo ter sido devidamente informado quanto às implicações éticas e legais associadas a tais práticas, isentando meus orientadores de quaisquer responsabilidades por eventuais infrações relacionadas a esses aspectos.

UFRRJ, 25 de abril de 2026

Nome do discente: André Christiano Claro Miguel

Assinatura do(a) discente.