

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

**DISSERTAÇÃO**

**DESENVOLVIMENTO DE UM *SOFTWARE* DE VISÃO  
COMPUTACIONAL PARA ESTUDO DO ESCOAMENTO DE  
CASCALHOS EM PENEIRA VIBRATÓRIA**

**CAROLINE DIAS GROSSI**

**2020**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA  
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

**DESENVOLVIMENTO DE UM *SOFTWARE* DE VISÃO  
COMPUTACIONAL PARA ESTUDO DO ESCOAMENTO DE  
CASCALHOS EM PENEIRA VIBRATÓRIA**

**CAROLINE DIAS GROSSI**

*Sob a orientação do Professor Dr.*  
**Luiz Augusto da Cruz Meleiro**

*e co-orientação do Professor Dr.*  
**Luís Américo Calçada**

Dissertação submetida como requisito parcial para a obtenção do grau de **Mestre em Engenharia Química**, no Curso de Pós-Graduação em Engenharia Química, Área de Concentração em Tecnologia Química.

Seropédica, RJ  
Dezembro de 2020

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

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

G878d Grossi, Caroline Dias, 1992-  
Desenvolvimento de um Software de Visão  
Computacional para Estudo do Escoamento de Cascalhos  
em Peneira Vibratória / Caroline Dias Grossi. -  
Seropédica, 2020.  
168 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/Engenharia Química, 2020.

1. Visão Computacional. 2. Processamento de  
Imagens. 3. Aprendizado de Máquina. 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/Engenharia Química. IV. Título.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO**  
**INSTITUTO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA QUÍMICA**  
**CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

**CAROLINE DIAS GROSSI**

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Química**, no Curso de Pós-Graduação em Engenharia Química, área de Concentração em Tecnologia Química.

DISSERTAÇÃO APROVADA EM: 18/12/2020.

**Conforme deliberação número 001/2020 da PROPPG, de 30/06/2020**, tendo em vista a implementação de trabalho remoto e durante a vigência do período de suspensão das atividades acadêmicas presenciais, em virtude das medidas adotadas para reduzir a propagação da pandemia de Covid-19, nas versões finais das teses e dissertações as assinaturas originais dos membros da banca examinadora poderão ser substituídas por documento(s) com assinaturas eletrônicas. Estas devem ser feitas na própria folha de assinaturas, através do SIPAC, ou do Sistema Eletrônico de Informações (SEI) e neste caso a folha com a assinatura deve constar como anexo ao final da tese / dissertação.

Membros da banca:

Luiz Augusto da Cruz Meleiro. Dr. UFRRJ. (Orientador/Presidente da banca)

Maurício Bezerra de Souza Junior. Dr. UFRJ

Rubens Gedraite. Dr. UFU



*Emitido em 2020*

**TERMO N° 555/2020 - PPGEQ (12.28.01.00.00.00.42)**

**(N° do Protocolo: NÃO PROTOCOLADO)**

*(Assinado digitalmente em 18/12/2020 18:55 )*

**LUIZ AUGUSTO DA CRUZ MELEIRO**

*PROFESSOR DO MAGISTERIO SUPERIOR*

*DEQ (12.28.01.00.00.00.45)*

*Matrícula: 2412659*

*(Assinado digitalmente em 21/12/2020 13:25 )*

**MAURÍCIO BEZERRA DE SOUZA JÚNIOR**

*ASSINANTE EXTERNO*

*CPF: 448.589.304-91*

*(Assinado digitalmente em 18/12/2020 18:58 )*

**RUBENS GEDRAITE**

*ASSINANTE EXTERNO*

*CPF: 010.616.098-20*

Para verificar a autenticidade deste documento entre em <https://sipac.ufrrj.br/documentos/> informando seu número:  
**555**, ano: **2020**, tipo: **TERMO**, data de emissão: **18/12/2020** e o código de verificação: **02bbd58aed**

## **AGRADECIMENTOS**

A Deus, que sempre esteve presente em todos os momentos da minha vida, me presenteando com força e saúde para buscar a realização dos meus sonhos. Nos momentos mais difíceis, Sua voz não me deixou desistir e me motivou a dar sempre o meu melhor.

A esta Universidade, que me acolheu e proporcionou todo o conhecimento e suporte para que este projeto pudesse ser desenvolvido.

Ao meu orientador, Prof. Dr. Luiz Augusto da Cruz Meleiro, pelo suporte técnico e incentivo imprescindíveis para a elaboração deste trabalho. Também pela confiança e liberdade concedidas, que fizeram com que o fluxo de ideias conjuntas levasse aos resultados obtidos. Obrigada por acreditar no meu potencial e confiar no meu trabalho.

A minha família, pela dedicação, compreensão e apoio no trilhar desse caminho. Sem vocês eu não teria o suporte físico e emocional necessários para mais essa conquista. Um agradecimento especial à minha filha, Isabella, por compreender, ainda que muito pequena, meus momentos de cansaço, impaciência e ausência. Você é o principal motivo que me faz seguir em frente buscando ser melhor a cada dia.

Aos membros da banca examinadora, Prof. Dr. Rubens Gedraite, Prof. Dr. Maurício Bezerra de Souza Jr e Prof. Dr. Duílio Tadeu da Conceição Junior, por aceitarem participar e contribuir com essa dissertação. Obrigada pelas críticas e posicionamentos que certamente me farão crescer profissionalmente.

Aos professores e funcionários da UFRRJ, aos amigos antigos e feitos no percurso e a todos que direta e indiretamente fizeram parte da minha formação, contribuindo intelectualmente e emocionalmente para que esse momento chegasse, o meu muito obrigada.

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.

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
<b>2</b>	<b>MOTIVAÇÃO</b>	<b>3</b>
<b>3</b>	<b>OBJETIVOS</b>	<b>4</b>
3.1	Objetivos Gerais	4
3.2	Objetivos Específicos	4
3.2.1	Aplicativo 1 – Monitoramento do Escoamento	4
3.2.2	Aplicativo 2 – Apoio ao Geólogo	4
<b>4</b>	<b>REVISÃO DE LITERATURA</b>	<b>5</b>
4.1	Exploração de Petróleo	5
4.1.1	Breve histórico da perfuração de poços de petróleo	5
4.1.2	O processo de perfuração	7
4.1.3	Problemas na perfuração de poços de petróleo	7
4.1.4	Sistema de controle de sólidos	9
4.2	Cascalho de Perfuração	10
4.2.1	Sistema mud-logging	10
4.2.2	Análise de cascalhos	11
4.2.2.1	Propriedades granulométricas e morfológicas	12
4.2.2.2	Análise de imagens aplicada à determinação granulométrica e morfológica	14
4.3	Visão Computacional	16
4.3.1	Processamento de imagens	17
4.3.1.1	Pré-processamento e pós-processamento de imagens	17
4.3.1.2	Segmentação	17
4.3.2	Extração de características	18
4.3.3	Técnicas de Inteligência Artificial	20
4.4	Trabalhos Relacionados à Análise de Cascalhos por Imagem	21
<b>5</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>39</b>
5.1	Imagem Digital	39
5.1.1	Amostragem e quantização	39

5.1.2	Teorema da convolução	40
<b>5.2</b>	<b>Filtragem Digital</b>	<b>41</b>
5.2.1	Manipulação de contraste	41
5.2.2	Filtros Lineares	43
5.2.3	Filtros não-lineares	44
<b>5.3</b>	<b>Técnicas de Segmentação</b>	<b>45</b>
5.3.1	Limiarização de Otsu	45
5.3.2	Algoritmo <i>k-means</i>	46
5.3.3	Transformada Discreta Bidimensional de Fourier	49
5.3.4	Transformada <i>Wavelets</i>	51
<b>5.4</b>	<b>Visão Computacional – Detectores de Objetos</b>	<b>55</b>
5.4.1	Harris Corner Detector	56
5.4.2	Speed Up Robust Features – SURF	58
5.4.3	Maximally Stable Extremal Region – MSER	60
<b>5.5</b>	<b>Características Texturais</b>	<b>61</b>
5.5.1	Matrizes de co-ocorrência	61
5.5.2	Descritores de Haralick	63
<b>5.6</b>	<b>Aprendizado de Máquina</b>	<b>65</b>
5.6.1	Aprendizado profundo	67
5.6.2	Redes neurais convolucionais	68
5.6.2.1	Camadas de convolução	69
	Camadas de <i>Pooling</i>	70
5.6.2.2	Camadas completamente conectadas	71
5.6.2.3	Modelos pré-treinados	72
<b>6</b>	<b>METODOLOGIA</b>	<b>76</b>
<b>6.1</b>	<b>Ensaio Experimentais</b>	<b>76</b>
6.1.1	Unidade experimental	76
6.1.2	Grupos de sólidos avaliados	76
6.1.2.1	Grupo I	77
6.1.2.2	Grupo II	77
6.1.2.3	Grupo III	78
6.1.2.4	Grupo IV	79
6.1.2.5	Grupo V	80
6.1.3	Procedimento experimental	80

<b>6.2</b>	<b>Desenvolvimento dos Aplicativos de Visão Computacional</b>	<b>81</b>
6.2.1	Aplicativo para monitoramento do escoamento de sólidos	81
6.2.2	Aplicativo para apoio do geólogo	83
<b>7</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>85</b>
<b>7.1</b>	<b>Grupo I</b>	<b>85</b>
7.1.1	Aplicativo 1 – Monitoramento do Escoamento	86
7.1.2	Aplicativo 2 – Classificação dos Sólidos	88
<b>7.2</b>	<b>Grupo II</b>	<b>90</b>
<b>7.3</b>	<b>Grupo III</b>	<b>93</b>
7.3.1	Porcentagem da calha preenchida por sólidos (%AP)	95
7.3.2	Velocidade de escoamento	96
7.3.2.1	Um sólido em escoamento	97
7.3.2.2	Vários sólidos em escoamento – Estudo da Calha Inteira	101
7.3.2.3	Vários Sólidos – Final da Calha	107
7.3.3	Estimativa da vazão mássica	112
<b>7.4</b>	<b>Grupo IV</b>	<b>113</b>
7.4.1	Detecção - monitoramento	113
7.4.2	Estimativa da velocidade de escoamento – Calha Inteira	115
7.4.3	Estimativa da velocidade de escoamento – Final de Calha	117
7.4.4	Aplicativo 2 – Classificação dos Sólidos	120
<b>7.5</b>	<b>Grupo V</b>	<b>126</b>
7.5.1	Detecção – Velocidade de Escoamento	127
7.5.2	Detecção – Porcentagem da tela na região de secagem preenchida por sólidos	131
7.5.3	Avaliação de tempo de processamento	136
<b>8</b>	<b>CONCLUSÕES</b>	<b>138</b>
<b>9</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b>	<b>140</b>
<b>10</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>141</b>

## LISTA DE FIGURAS

Figura 1. Profundidade alcançada na perfuração ao longo dos anos. ....	6
Figura 2. Profundidade total dos principais poços brasileiros. ....	6
Figura 3. Esquema de um sistema de controle de sólidos brasileiro. ....	9
Figura 4. Relação entre arredondamento, esfericidade e porosidade. ....	13
Figura 5. Sistema de câmera dupla do CAMSIZER. ....	15
Figura 6. Passos para o projeto de um sistema de visão computacional. ....	16
Figura 7. Interface de análise do <i>VisioRock</i> . ....	22
Figura 8. (A) Classe E; (B) Classe L; (C) Classe H. Fonte: MARANA et al., 2009. ....	23
Figura 9. Processamento de imagens do sistema de varredura. Fonte: LIAO et al., 2010. ....	24
Figura 10. Reconstrução de objetos com bordas incompletas. Fonte: LIAO et al., 2010. ....	24
Figura 11. Classes de minerais classificados pela ANN. Fonte: KO & SHANG, 2011. ....	25
Figura 12. (A) Imagem original; (B) Resultado do <i>Blob Coloring</i> . ....	26
Figura 13. Amostras das três categorias de tamanhos de partículas. (A) 0 – 20% de finos; (B) 40 – 60% de finos; (C) 80-100% de finos. Fonte: KISTNER et al. (2013). ....	27
Figura 14. (A) Imagem original; (B) Objetos identificados. Fonte: MATTA, 2014. ....	29
Figura 15. (A) Imagem original; (B) ROI; (C) Objetos detectados. Fonte: MATTA, 2014. ....	29
Figura 16. (A) Imagem de referência; (B) Imagem binarizada por limiar comum; (C) Imagem final, após processamento. Fonte: CIPELLI & ASSIS, 2014. ....	30
Figura 17. Processamento manual de imagens de pedras. (A) Imagem original; (B) borda aprimorada; (C) Imagem binarizada; (D) Imagem segmentada; (E) Região de partícula; (F) Imagens detectadas com precisão. Fonte: HAMZELOO et al., 2014. ....	31
Figura 18. Representação da divisão da imagem original em 25 outras imagens. ....	32
Figura 19. Distribuição granular (a) A; (b) B; (c) C; (d) D. Fonte: FACCO et al., 2017. ....	34
Figura 20. Unidade experimental de ensaios com peneira piloto e suspensão de areia e goma xantana 0,1%. Fonte: Adaptado de Barbosa (2018). ....	35
Figura 21. (A) Imagem original; (B) Recorte da região de análise; (C) Resultado do processamento de imagem. Fonte: SILVA, 2017. ....	35
Figura 22. Exemplo esquemático do funcionamento da peneira piloto durante ensaios. ....	36
Figura 23. Resposta da detecção da área de piscina. Fonte: Barbosa, 2018. ....	37
Figura 24. Detecção da porcentagem da área da região de secagem preenchida por sólidos. Fonte: Barbosa, 2018. ....	37
Figura 25. Ilustração do método de aferição de velocidade de escoamento. Fonte: Barbosa, 2018. ....	38
Figura 26. (a) Sequência de amostragem, (b) sequência de quantização. ....	40
Figura 27. Representação de uma operação de convolução entre matrizes. Fonte: STOLFI, 2008. ....	41
Figura 28. Expansão de contraste. Fonte: GOMES, 2001. ....	42
Figura 29. Expansão de contraste linear e não linear. Fonte: GOMES, 2001. ....	42
Figura 30. Equalização histográfica. Fonte: GOMES, 2001. ....	43
Figura 31. (A) Fechamento; (B) Abertura. Fonte: Adaptado de COSTA, 1998. ....	44
Figura 32. Método de Otsu – Variância Interclasse. Fonte: CC-BY-AS. ....	46

Figura 33. Fluxograma do algoritmo do Método de Otsu. Fonte: O autor. ....	46
Figura 34. Agrupamento de um mesmo conjunto de dados segundo critérios diferentes. ....	47
Figura 35. Algoritmo <i>k-means</i> . Fonte: Adaptado de MALHEIROS, 2017. ....	48
Figura 36. Fluxograma do algoritmo do Método de <i>k-means</i> . Fonte: O autor. ....	49
Figura 37. Fluxograma do algoritmo do Método da Transformada de Fourier. Fonte: O autor. ....	51
Figura 38. Representação da decomposição com TW's para um nível. Fonte: Mathworks. ....	53
Figura 39. Fluxograma do algoritmo do Método da Transformada de Wavelets. Fonte: O autor. ....	54
Figura 40. Fluxograma do algoritmo de detecção de pontos de interesse. Fonte: O autor. ....	56
Figura 41. Respostas possíveis para a correlação no algoritmo do detector de Harris. (A) Pontos de região homogênea, superfície plana, fundo ou interior de objetos. (B) Pontos de borda. (C) Pontos de quina. Fonte: Adaptado de JESUS, 2019. ....	57
Figura 42. (A) Matriz que representa a imagem original; (B) Matriz que representa a imagem integral; (C) Ilustração do sistema de coordenadas. Fonte: Adaptado de BRAZ JUNIOR, 2009. ....	58
Figura 43. Linha superior: filtros baseados em funções Gaussianas de segunda ordem. Linha inferior: aproximações dos filtros da linha superior para filtros caixa. ....	59
Figura 44. Ilustração do (A) espaço de escala e da (B) supressão de não máximos do método SURF. Fonte: Adaptado de BRAZ JUNIOR, 2009. ....	59
Figura 45. Detecção de regiões extremas utilizando o algoritmo MSER. (A) Imagem original; (B) T = 0; (C) T = 50; (D) T = 100; (E) T = 150; (F) T = 200; (G) T = 250; (H) = Regiões extremas detectadas. Fonte: PEREIRA, 2018. ....	60
Figura 46. Direções possíveis para o cálculo da matriz de co-ocorrência. ....	62
Figura 47. Mecanismo para construção de uma GLMC. Fonte: CONCI, 2015. ....	62
Figura 48. Exemplo de <i>underfitting</i> e <i>overfitting</i> . Fonte: Adaptado de MARQUES, 2018. ....	66
Figura 49. (A) Cão branco da raça <i>Samoyed</i> ; (B) Lobo branco. ....	67
Figura 50. (A) ANN com camadas completamente conectadas. (B) ANN com interações esparsas entre camada de entrada e intermediária. Fonte: Adaptado de MARQUES, 2018. ....	69
Figura 51. (A) Formação dos mapas de características. Fonte: SOUSA, 2019. ....	70
Figura 52. Aplicação de uma camada de <i>pooling</i> com função máximo. ....	71
Figura 53. Arquitetura da CNN <i>LeNet</i> . Fonte: ANWAR, 2019. ....	73
Figura 54. Arquitetura da CNN <i>AlexNet</i> . Fonte: ANWAR, 2019. ....	74
Figura 55. Arquitetura da CNN <i>GoogLeNet</i> . Fonte: MARQUES, 2018. ....	74
Figura 56. Arquitetura da CNN <i>VGGNet</i> . Fonte: ANWAR, 2019. ....	75
Figura 57. Unidade Experimental. ....	76
Figura 58. Dosador Vibratório. ....	76
Figura 59. Grupo I: (a) milho, (b) arroz, (c) ervilhas e (d) feijão. Fonte: O autor. ....	77
Figura 60. Quarto colorido artificialmente. Fonte: O autor. ....	77
Figura 61. Subgrupos de quartzo divididos por tamanho. Fonte: O autor. ....	77
Figura 62. Grupo III: (A) areia, (B) mármore, (C) quartzo colorido artificialmente e (D) granito. Fonte: O autor. ....	78
Figura 63. (A) Conjunto de peneiras vibratórias laboratoriais; (B) amostras do grupo III após separação granulométrica. Fonte: O autor. ....	78

Figura 64 Amostras de cascalho de um mesmo poço separadas segundo profundidade. Fonte: O autor. ....	79
Figura 65 Amostra de cascalho separada em cinco frações granulométricas. ....	79
Figura 66. Circulação da suspensão de areia e goma xantana 0,1% na unidade experimental durante ensaios. Fonte: Barbosa, 2018. ....	80
Figura 67. Algoritmo simplificado de monitoramento do escoamento de sólidos. ....	83
Figura 68. Milho. 30% de vibração. %AP = 37,4%. NGE = 104. NGR= 108. <b>Erro = 3,7%</b> . ....	86
Figura 69. Arroz. 35% de vibração. %AP = 63,9%. NGE = 642. NGR= 597. <b>Erro = 7,5%</b> . ....	87
Figura 70. Ervilhas. 35% de vibração. %AP = 49,2%. NGE = 204. NGR= 228. <b>Erro = 5,2%</b> . ....	87
Figura 71. Feijão. 30% de vibração. %AP = 53,9%. NGE = 131. NGR= 126. <b>Erro = 3,9%</b> . ....	87
Figura 72. Milho e ervilhas. 40% de vibração. %AP = 55,8%. NGE = 143. NGR= 137. ....	88
Figura 73. Milho e arroz. 40% de vibração. %AP = 24,9%. NGE = 38. NGR= 74 (32 de milho e 42 de arroz). Fonte: O autor. ....	88
Figura 74. Escoamento de ervilhas. Fonte: O autor. ....	88
Figura 75. Treinamento supervisionado das camadas completamente conectadas da CNN proposta. Fonte: O autor. ....	89
Figura 76. Matriz confusão da identificação dos grãos e suas misturas. Fonte: O autor. ....	89
Figura 77. Etapas do processamento de imagens para o grupo II. Fonte: O autor. ....	90
Figura 78. Segmentação. Escoamento de pedras a 40% de vibração. Fonte: O autor. ....	91
Figura 79. (A) Imagem de referência para identificação dos sólidos medidos; (B) Tabela de características extraídas para todos os objetos identificados. Fonte: O autor. ....	92
Figura 80. Segmentação de cascalho em escoamento em peneiras vibratórias. Fonte: O autor. ....	93
Figura 81. Representação das frações de mármore. Fonte: O autor. ....	94
Figura 82. Detecção de fragmentos dos quatro materiais diferentes. ....	94
Figura 83. Detecção de fragmentos de granito nos cinco tamanhos propostos pela metodologia. (A) 2,36mm; (B) 1,18mm; (C) 0,60mm; (D) 0,30mm; (E) 0,15mm. Fonte: O autor. ....	95
Figura 84. Validação da estimativa %AP. (A) 10%; (B) 40%; (C) 80%; (D) 100%. ....	96
Figura 85. Correspondência entre frames para os detectores (A) MSER e (B) Harris. Fonte: O autor. ....	98
Figura 86. Validação da estimativa de velocidade para 25% de intensidade de vibração. Fonte: O autor. ....	98
Figura 87. Validação da estimativa de velocidade para 30% de intensidade de vibração. Fonte: O autor. ....	99
Figura 88. Validação da estimativa de velocidade para 35% de intensidade de vibração. ....	99
Figura 89. Desempenho do detector MSER para um sólido em escoamento. Fonte: O autor. ....	100
Figura 90. Eliminação de ruídos no algoritmo para cálculo de velocidade na calha inteira: (A) imagem com todos os pontos detectados pelo algoritmo; (B) imagem sem ruídos. Fonte: O autor. ....	102
Figura 91. Validação da estimativa de velocidade para o quartzo. Fonte: O autor. ....	103
Figura 92. Validação da estimativa de velocidade para o granito. Fonte: O autor. ....	104
Figura 93. Validação da estimativa de velocidade para o mármore. Fonte: O autor. ....	105
Figura 94. Relação entre as variáveis VE e %AP para o quartzo nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%. Fonte: O autor. ....	106
Figura 95. Eliminação de ruídos no algoritmo para cálculo de velocidade no último trecho da calha: (A) imagem com todos os pontos detectados pelo algoritmo; (B) imagem sem ruídos. Fonte: O autor. ....	107

Figura 96. Comparação as velocidades de escoamento do quartzo a 35% de vibração estimada por três detectores diferentes. Fonte: O autor.....	107
Figura 97. Validação da estimativa de velocidade para o quartzo. Fonte: O autor.....	109
Figura 98. Validação da estimativa de velocidade para o granito. Fonte: O autor.....	110
Figura 99. Validação da estimativa de velocidade para o mármore. Fonte: O autor. ....	111
Figura 100. Relação entre as variáveis VE e %AP para o quartzo nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%. Fonte: O autor. ....	111
Figura 101. Relação entre vazão mássica e os descritores (A) contraste, (B) %AP e (C) homogeneidade, para um escoamento de quartzo a 30% de vibração em calha inteira.....	113
Figura 102. Identificação de cascalho ensaiado em laboratório: (A) imagem pré-processada; (B) segmentação pelo algoritmo <i>k-means</i> ; (C) segmentação pela DTF-2D. Fonte: O autor.....	114
Figura 103. Identificação de cascalho em peneiras reais: (A) imagem pré-processada; (B) segmentação pelo algoritmo <i>k-means</i> ; (C) segmentação pela DTF-2D. Fonte: O autor. ....	114
Figura 104. Validação da velocidade para o cascalho a (A) 25%, (B) 30% e (C) 35% de vibração utilizando calha inteira. Fonte: O autor.....	116
Figura 105. Relação entre vazão mássica estimada e %AP para o cascalho nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%. Fonte: O autor. ....	117
Figura 106. Validação da velocidade para o cascalho a (A) 25%, (B) 30% e (C) 35% de vibração utilizando um trecho da calha. Fonte: O autor. ....	118
Figura 107. Relação entre vazão mássica estimada e %AP para o cascalho nas intensidades de vibração (A) 25%, (B) 30% e (C) 35% considerando um trecho da calha. Fonte: O autor. ....	119
Figura 108. Relação entre estimadores de vazão para o cascalho utilizando quatro descritores e considerando calha inteira. Fonte: O autor.....	120
Figura 109. Pré-tratamento do banco de imagens. (A) Técnica de fragmentação. (B) Sub-imagens 300x300. (C) Sub-imagens 600x600. Fonte: O autor.....	121
Figura 110. Matriz Confusão da classificação do cascalho segundo: (A) tamanho, utilizando DS1 e rede <i>AlexNet</i> . Acurácia: 60,25%; (B) categoria, utilizando DS1 e rede <i>AlexNet</i> . Acurácia: 46,48%. Fonte: O autor. ....	122
Figura 111. Matriz Confusão da classificação do cascalho segundo (A) tamanho, utilizando DS1 e rede não pré-treinada. Acurácia: 48,51%; (B) categoria, utilizando DS1 e rede não pré-treinada. Acurácia: 36,48%. Fonte: O autor. ....	123
Figura 112. Matriz Confusão da classificação do cascalho segundo (A) tamanho, utilizando DS2 e rede <i>AlexNet</i> . Acurácia: 94,00%; (B) categoria, utilizando DS2 e rede <i>AlexNet</i> . Acurácia: 61,67%. Fonte: O autor.....	124
Figura 113. (A) Imagem de entrada do aplicativo 2. (B) Imagem binarizada utilizada no cálculo das propriedades dos objetos. Fonte: O autor. ....	125
Figura 114. Bordas detectadas dos cascalhos escolhidos para validação. Fonte: O autor. ....	125
Figura 115. Frame retirado de vídeo do experimento 3. Fonte: O autor. ....	127
Figura 116. (A) Frame original retirado do experimento 8. (B) Frame após segmentação pelo método de Fourier. Fonte: O autor.....	127
Figura 117. Resultado da velocidade estimada com segmentação de Fourier. Fonte: O autor. ....	128

Figura 118. (A) Frame original retirado do experimento 8. (B) Frame após segmentação pelo método de Wavelets. Fonte: O autor.....	129
Figura 119. Resultado da velocidade estimada com segmentação com wavelets. Fonte: O autor.....	129
Figura 120. Velocidade estimadas ao longo do tempo para o experimento 4. Fonte: O autor.....	130
Figura 121. Velocidade estimadas ao longo do tempo para o experimento 17. Fonte: O autor.....	131
Figura 122. Velocidade estimadas ao longo do tempo para o experimento 10. Fonte: O autor.....	131
Figura 123. Velocidade estimadas ao longo do tempo para o experimento 24. Fonte: O autor.....	131
Figura 124. Resultado da %AP com segmentação por cores para todos os experimentos.....	132
Figura 125. Resultado da %AP com segmentação por cores para os experimentos (A) 9 e (B) 15.....	132
Figura 126. Resposta da detecção da porcentagem da área da região de secagem preenchida por sólidos. Fonte: Barbosa, 2018.....	133
Figura 127. Treinamento da CNN dividida em 4 classes para os ensaios com suspensão de areia. ....	134
Figura 128. Resultado da CNN dividida em 4 classes. Fonte: O autor.....	134
Figura 129. Treinamento da CNN dividida em 6 classes para os ensaios com suspensão de areia. ....	135
Figura 130. Resultado da CNN dividida em 6 classes. Fonte: O autor.....	135

## LISTA DE TABELAS

Tabela 1. Problemas no processo de perfuração de poços. Fonte: Adaptado de TAVARES, 2006. ....	8
Tabela 2. Técnicas aplicadas a cada tamanho de partícula. Fonte: Adaptado de ORDOÑEZ (2015). ....	12
Tabela 3. Classificação de fragmentos de rochas pelo tamanho. ....	12
Tabela 4. Resumo das estimativas calculadas para cada grupo de sólidos. Fonte: O autor. ....	84
Tabela 5. Resultados de vazão mássica dos cereais. Fonte: O autor. ....	85
Tabela 6. Validação da estimativa de tamanho de fragmento para o grupo II. Fonte: O autor. ....	92
Tabela 7. Validação da porcentagem da calha preenchida por sólidos (%AP). Fonte: O autor. ....	96
Tabela 8. Dados experimentais de velocidade para um sólido em escoamento. Fonte: O autor. ....	97
Tabela 9. Validação da estimativa de velocidade para um sólido em escoamento. ....	100
Tabela 10. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira. Fonte: O autor. ....	102
Tabela 11. Respostas médias dos descritores MSER, Harris e SURF para um escoamento de quartzo a 35% de vibração. Fonte: O autor. ....	108
Tabela 12. Validação da velocidade para vários sólidos utilizando um trecho da calha. ....	108
Tabela 13. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira. Fonte: O autor. ....	115
Tabela 14. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira. Fonte: O autor. ....	117
Tabela 15. Descritores geométricos e propriedades estatísticas. Fonte: O autor. ....	125
Tabela 16. Validação do tamanho de partícula. Fonte: O autor. ....	126
Tabela 17. Resultado da estimativa de velocidade para os experimentos com suspensão de areia e goma xantana 0.1%. Fonte: O autor. ....	130
Tabela 18. Relação entre o número de pontos e o tempo de cada simulação realizada para o escoamento de suspensão de areia e goma xantana. Fonte: O autor. ....	136

## RESUMO

GROSSI, Caroline Dias; **Desenvolvimento de um *Software* de Visão Computacional para Estudo do Escoamento de Cascalhos em Peneira Vibratória**. 2020. 168p. Dissertação (Mestrado em Engenharia Química, Tecnologia Química). Instituto de Tecnologia, Departamento de Engenharia Química, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2020.

O petróleo é um combustível fóssil de grande interesse comercial, podendo ser encontrado *onshore* e *offshore*. O processo de perfuração tem sua complexidade aumentando proporcionalmente ao aumento da profundidade do poço, estando sujeito a problemas operacionais que podem colocar em risco a integridade das instalações, dos operadores e do meio ambiente, além de ocasionarem tempo não produtivo. Um indicador pouco explorado de causas de instabilidades durante a perfuração são as características do cascalho que chega à superfície. Informações como distribuição de tamanhos, velocidade e volume com que retornam do poço podem sugerir problemas como desmoronamento e perda de circulação. O primeiro equipamento a receber a lama de perfuração é a peneira vibratória e, por isso, este estudo foi direcionado a este equipamento. A Visão Computacional é uma tecnologia que tem como finalidade a automatização e a integração de processos relacionados à análise das informações contidas em vídeos ou imagens, utilizando princípios do sentido biológico da visão. Nos últimos anos, diversos trabalhos voltados para a indústria de petróleo têm se dedicado à aplicações dessas técnicas. O objetivo desse trabalho foi aplicar técnicas de visão computacional, processamento de imagens e inteligência artificial na análise de imagens de cascalho em peneiras vibratórias, de forma a desenvolver um *software* capaz de monitorar certas variáveis do escoamento e associá-las a possíveis instabilidades no processo de perfuração do poço. Para o desenvolvimento do *software* de visão computacional, foram utilizados diversos tipos de sólidos diferentes, que foram divididos em cinco grupos: i) cereais de milho, arroz, feijão e ervilhas; ii) fragmentos de quartzo coloridos artificialmente; iii) fragmentos de quartzo, mármore, granito e areia; iv) cascalho real, oriundo de sonda de perfuração; e v) suspensão de areia e goma xantana 0,1%. Para cada grupo, diferentes técnicas de segmentação foram avaliadas para detecção de objetos, dentre elas, k-means e Transformadas de Fourier e Wavelets. Os resultados obtidos foram as estimativas de preenchimento da tela da peneira por sólidos e as suas velocidades de escoamento, além de estimativas de dimensões e formas geométricas como tamanho, circularidade, arredondamento e excentricidade dos sólidos. Foram estudados alguns detectores de correspondências e os de melhor desempenho para essa abordagem foram MSER, Harris e SURF. Também foram avaliadas características texturais como possíveis estimadores qualitativos de vazão mássica do cascalho na peneira. Além disso, redes neurais convolucionais foram utilizadas para a classificação dos sólidos quando a tamanho, composição e percentual de preenchimento da peneira. Os resultados mostraram que o *software* de visão computacional desenvolvido é versátil, pois conseguiu realizar boas estimativas dessas propriedades para uma grande variedade de materiais. Na maioria dos casos foi possível estimar a porcentagem de preenchimento da peneira por sólidos e a sua velocidade de escoamento com erros menores do que 10%, considerando os valores médios. O estudo proporcionou ampla avaliação das técnicas citadas e os resultados obtidos sugerem ser possível a implementação de um sistema de monitoramento de cascalho em tempo real.

**Palavras-chave:** visão computacional, processamento de imagens, aprendizado de máquina.

## ABSTRACT

GROSSI, Caroline Dias. **Development of a Computational Vision Framework for Analysis of Gravel Flow Systems in Vibration Channel**. 2020. 168p. Thesis (Master of Science in Chemical Engineering, Chemical Technology). Institute of Technology, Department of Chemical Engineering, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2020.

*Oil is a fossil fuel of great commercial interest and can be found onshore and offshore. The drilling process has its complexity increasing proportionally to the good depth, being subject to operational problems that can put at risk the integrity of the installations, the operators, and the environment, besides causing non-productive time. A poorly exploited indicator of instabilities is the gravel reaching the surface. Information such as size distribution, speed, and volume with which they return from the well can suggest problems such as crumbling and loss of circulation. The first equipment to receive the drilling mud is the vibrating sieve, and therefore, this study will be directed to this equipment. The Computational Vision is a technology that has as a purpose the automation and integration of processes through the information contained in videos or images using principles of the biological sense of vision. In the last years, several works focused on the oil industry have been dedicated to the applications of these techniques. The objective of this work is to apply computational vision techniques, image processing, and artificial intelligence in the analysis of gravel in vibrating screens, to develop an application capable of monitoring flow variables and detect possible instabilities. Several different materials were used, divided into five groups: i) corn, rice, beans, and peas; ii) artificially colored quartz fragments; iii) quartz fragments, marble, granite, and sand; iv) royal gravel from drilling rigs; and v) 0.1% sand and xanthan gum suspension. Each group used different segmentation techniques for object detection, among them, k-means and Fourier and Wavelets Transform. Estimates of sieve screen-filling and flow velocity were validated, as well as measures such as size, circularity, roundness, and eccentricity of solids. Some matching detectors were studied, and the best performers for this approach were MSER, Harris, and SURF. Texture characteristics were also evaluated as possible qualitative mass flow estimators. Also, convolutional neural networks were evaluated for solids classification when size, composition, and sieve filling. The limitations found were corrected according to the complexity of the study groups. The results show that the application is versatile, and can make good estimates for a variety of materials. In most cases, it was possible to estimate the percentage of sieve filling and the flow velocity with errors of less than 10% considering average values. The study provided great learning about the cited techniques, and the promising results suggest that it is possible to implement a gravel monitoring system in real-time.*

**Keywords:** computer vision, image processing, machine learning.

# 1 INTRODUÇÃO

A história do petróleo no Brasil começou em 1939, entretanto, somente na década de 60 o primeiro poço marítimo foi perfurado. Na perfuração, as formações rochosas são trituradas pelo peso e rotação da broca e os fragmentos de rocha, chamados cascalhos, são levados à superfície pelo fluido de perfuração (MATHIAS, 2016). Depois de perfurar um trecho, ocorre a cimentação, que protege as paredes do poço e evita problemas de desmoronamento e contaminação, além de servir de sustentação para a coluna de perfuração (CHIPINDU, 2010).

O aumento da profundidade faz com que o processo seja cada vez mais complexo, estando sujeito a problemas operacionais que podem colocar em risco a integridade das instalações, dos operadores e do meio ambiente, além de ocasionarem tempo não produtivo. Uma forma de minimizar a ocorrência desses problemas é a implementação de um sistema de coleta de dados e monitoramento de parâmetros operacionais que permita a tomada de decisão e intervenção no processo (TAVARES, 2006).

Muitas das instabilidades estão relacionadas ao desmoronamento de poço e podem ser identificadas na superfície a partir de análises do cascalho que retorna junto ao fluido de perfuração. As amostras são coletadas das peneiras vibratórias, primeiro equipamento a receber a carga fluido/cascalho, chamada lama e alterações na vazão de sólidos, granulometria e morfologia são indicativos de que algo não está ocorrendo como planejado.

A análise é realizada por um geólogo na cabine *mud-logging*, que classifica os fragmentos de acordo com tamanho, forma, textura, cor, brilho, dentre outros aspectos. Essa caracterização é feita visualmente, o que aumenta o tempo de resposta e reduz a precisão dos resultados, uma vez que depende da experiência do operador (FAGUNDES, 2018).

Existem equipamentos capazes de fazer a caracterização granulométrica e morfológica a partir de análise dinâmica de imagens, como o QICPIC® e o CAMSIZER®, que retornam resultados precisos em menor tempo, entretanto, a amostra analisada precisa passar por um pré-tratamento, não possibilitando a entrega de resultados em tempo real.

A aplicação de técnicas de visão computacional, aliadas ao processamento de imagens e aprendizado de máquina, vem sendo explorada pela indústria de petróleo nos últimos anos com diversas finalidades, dentre as quais a análise das características do cascalho ganha destaque em diversos trabalhos.

A Visão Computacional, também chamada visão de máquina, é uma tecnologia que tem como finalidade a automatização e integração de processos através de informações contidas em vídeos ou imagens utilizando princípios do sentido biológico da visão. Esta técnica foi teorizada na década de 1950, junto a Inteligência Artificial, mas somente anos mais tarde foi possível aplicá-la, quando a capacidade de processamento dos computadores foi aprimorada.

A Visão Computacional tem aplicabilidade em diversos segmentos da indústria como, por exemplo, calibração de padrões (MARTINS, 1999), reconhecimento de pessoas (SOUZA & MARANA, 2004), caracterização de partículas sólidas (FRICK, 2008), auxílio a diagnósticos de doenças (MACEDO, 2012), reconhecimento de padrões (ALEXANDRE et al., 2013), controle de qualidade (LIMA E CARVALHO, 2014), estimativas de tamanho e forma de objetos (FACCO et al., 2017) e automação inteligente de processos (BORBA FILHO, 2019).

No segmento da análise de cascalho de perfuração de poços de petróleo Marana et al. (2009) propuseram a identificação do volume de sólidos no escoamento em peneira vibratória utilizando quatro classificadores inteligentes distintos, (i) floresta de caminhos ótimos, (ii) redes neurais artificiais, (iii) máquina de suporte de vetores e (iv) classificador bayesiano. Os algoritmos propostos não realizam a detecção de objetos e a tarefa de classificação é realizada a partir de quatro características de textura (Haralick et al., 1973): (i) energia, (ii) entropia, (iii)

homogeneidade e, (iv) contraste.

Liao et al. (2010) apresentou uma abordagem diferente, utilizando características morfológicas baseadas em dados estatísticos e processamento digital de imagens para estimar área, volume, circularidade, esfericidade e peso, para partículas de densidade conhecida. Guilherme et al. (2011) deram sequência ao trabalho de Marana et al. (2009) e propuseram duas outras técnicas de estimativa de volume de sólidos em tempo real: regressão de suporte de vetores e funções de ajuste. Serapião et al. (2011), propôs a detecção dos sólidos pela técnica de *blob coloring*.

Matta (2014), Matta et al. (2014)<sup>1</sup>, Matta et al. (2014)<sup>2</sup>, propuseram um algoritmo em que o usuário escolhe as técnicas de filtragem e segmentação de acordo com a imagem apresentada, onde é possível contar os objetos e calcular a área média; Cipelli e Assis (2014) complementaram o trabalho anterior melhorando estimativas de área média em partículas e estreitando o recorte de análise com a delimitação de uma região de interesse (ROI).

Khojasteh et al. (2015) propuseram a detecção automática de formações geológicas em poços de petróleo no Irã baseada em análise de imagens e em máquinas de vetores de suporte (SVM). As características extraídas das imagens de cascalho limpo com auxílio do algoritmo *fuzzy c-means* (FCM), foram utilizadas pela SVM para a classificação dos sólidos. Silva (2017) propôs a avaliação da dinâmica de funcionamento da peneira vibratória com escoamento de areia utilizando técnicas de processamento de imagens. O estudo utilizou um protótipo em escala piloto que simula o fluxo da lama com areia e visa avaliar como algumas variáveis operacionais influenciam a porcentagem da área da peneira ocupada e o teor de umidade dos sólidos. Esse estudo tem grande relevância, uma vez que aponta outras variáveis que podem ser monitoradas por análise de vídeos.

Além desses, outros trabalhos aplicados à indústria de mineração têm relevância e podem ter técnicas aplicadas à análise de cascalho, como redes neurais artificiais (KO & SHANG, 2011; KHORRAM et al., 2011; HAMZELOO et al., 2014); transformadas de *wavelets* e pirâmides direcionáveis (KISTNER et al., 2013); análise de textura multivariada e multirresolução (FACCO et al., 2017); e transformada de Fourier e filtros de Gabor (YAGHOUBI et al., 2019).

O presente trabalho visa aplicar técnicas de visão computacional, *machine learning*, processamento de imagem e *deep learning* para a análise de sólidos escoando em calha vibratória e em peneira piloto. O software MatLab© foi utilizado como ferramenta de apoio para avaliação de textura e características morfológicas dos sólidos, bem como para o cálculo estimativas úteis para previsão de instabilidades no processo de perfuração de poços.

## 2 MOTIVAÇÃO

O primeiro passo para evitar acidentes durante a perfuração de poços de petróleo é a identificação precoce de problemas operacionais, impedindo que eles aumentem e causem danos importantes às instalações, operadores e meio-ambiente. Dentre os mais comuns, têm-se como consequência a perda de circulação, o alargamento de poço e a prisão de coluna, que podem ser detectados na superfície com a análise da lama que retorna do poço. Uma alternativa para a previsão e minimização desses eventos é a implementação de um sistema de coleta de dados e monitoramento de parâmetros operacionais que permita a tomada de decisão e intervenção no processo.

A lama que retorna do poço desemboca no sistema de controle de sólidos, que separa fragmentos de rocha do fluido de perfuração. A primeira operação desse sistema envolve um conjunto de peneiras vibratórias, de onde são retiradas amostras para a caracterização da formação rochosa sendo perfurada. O intervalo de amostragem é de 9 horas para zonas de baixo interesse e 3 horas para zonas de maior interesse, sendo possível reduzir o tempo em caso de suspeita de problemas operacionais. A caracterização é feita na cabine *mud-logging* por um geólogo e é dada por inspeção visual em microscópio e comparação do aspecto observado com uma cartilha padrão, o que conta com alta experiência do profissional (FAGUNDES, 2018). O intervalo de amostragem é muito grande e, ainda que fosse menor, a caracterização laboratorial do cascalho envolve uma série de procedimentos que levam tempo, impedindo a avaliação em tempo real.

A motivação deste trabalho é o desenvolvimento de uma estratégia para a redução drástica nesses intervalos, com a utilização de câmeras para filmar a operação das peneiras ininterruptamente. A proposta é realizar o processamento e a análise dessas imagens de vídeo automaticamente e em tempo real, por meio de sistemas inteligentes de monitoramento aliados a técnicas de processamento de imagem, que podem, inclusive, servir para a emissão de alertas visuais e sonoros. Outra motivação é a automatização da caracterização dos cascalhos baseado em imagens com um sistema de apoio ao geólogo, de forma a minimizar falhas humanas.

## 3 OBJETIVOS

### 3.1 Objetivos Gerais

O presente trabalho tem como objetivo desenvolver dois aplicativos que utilizem técnicas de visão computacional, *machine learning*, processamento de imagens e *deep learning* como ferramentas para auxiliar duas atividades na perfuração de poços de petróleo:

- (i) monitoramento do escoamento de cascalho em peneiras vibratórias, de modo a identificar e prever instabilidades durante o processo de perfuração;
- (ii) apoio ao geólogo na identificação e análise das formações geológicas perfuradas.

O estudo pretende explorar características texturais e morfológicas de diversos sólidos e realizar o cálculo de estimativas utilizando como ferramenta o *software* MatLab© R2019b.

### 3.2 Objetivos Específicos

#### 3.2.1 Aplicativo 1 – Monitoramento do Escoamento

- Construir uma unidade experimental capaz de simular o escoamento de cascalho em peneiras vibratórias;
- Obter banco de vídeos de condições variadas de operação, de forma a simular alguns dos cenários de escoamento encontrados em peneiras reais;
- Realizar ensaios com sólidos variados, buscando as melhores técnicas de processamento de imagens e aprendizado de máquina para cada grupo de sólidos;
- Realizar estimativas qualitativas e quantitativas de escoamento de cascalhos baseadas em imagens de vídeo;
- Realizar ensaios para validar o aplicativo e a unidade experimental construída;
- Definir parâmetros de normalidade de escoamento para implementar alertas de problemas operacionais.

#### 3.2.2 Aplicativo 2 – Apoio ao Geólogo

- Obter banco de imagens de cascalhos a partir de fotografias;
- Desenvolver um aplicativo capaz de classificar os sólidos quanto ao seu tamanho e formação litológica, além de calcular estimativas geométricas e padrões de forma;
- Realizar medições em laboratório com a finalidade de validar estimativas propostas.

## 4 REVISÃO DE LITERATURA

### 4.1 Exploração de Petróleo

#### 4.1.1 Breve histórico da perfuração de poços de petróleo

O petróleo é utilizado para fins diversos desde os primórdios da civilização, quando podia ser facilmente encontrado no solo em regiões do Oriente Médio. Era largamente comercializado como cola de ladrilho e pedras, graxa para couro e lubrificante para carruagens, até que em meados do século XIX teve uma nova aplicação: a utilização como combustível para lâmpadas, competindo comercialmente com o óleo de carvão, que dominava o mercado na época.

Com essa motivação e acreditando na possibilidade de comercializar o “óleo iluminante” em larga escala, George Bissel, advogado visionário de Nova York, contratou Edwin Laurentine Drake, conhecido como Coronel Drake, que em 1859 foi o primeiro homem a conseguir extrair petróleo do solo, a 23 metros de profundidade, a partir da técnica de perfuração (MBP COPPE, 2014).

O interesse comercial nesse combustível esteve em alta por cerca de 20 anos, até que então, Thomas Edison desenvolveu o sistema de iluminação a partir de energia elétrica, fazendo com que a procura por petróleo entrasse em declínio. Anos mais tarde, já no século XX, com a invenção dos motores a combustão a diesel e gasolina, viu-se um novo horizonte e começou então a corrida do petróleo pelo mundo.

A história do petróleo no Brasil começou em 1939, quando foi descoberta a primeira reserva de petróleo em solo nacional, em Salvador, Bahia. Infelizmente não se tratava de uma reserva economicamente viável, mas sua descoberta foi fundamental para incentivar a busca por novos reservatórios e desenvolver a atividade petrolífera no país. Dois anos depois, em 1941, foi encontrada em Candeias, também na Bahia, a primeira reserva comercializável de petróleo no Brasil.

O país pioneiro no quesito perfuração de poços foram os EUA, porém seus esforços eram concentrados na produção terrestre, chamada *onshore*. O Brasil, no entanto, possui a maior parte de suas reservas no mar, *offshore*, não sendo muito beneficiado com o ‘*Know How*’ americano: foi necessário criar uma estratégia completamente nova, uma tecnologia adaptada à realidade brasileira e, assim, em 1953, foi fundada a Petrobras, empresa responsável pelo setor no país (ORTIZ NETO & COSTA, 2007).

Para o sucesso da operação são necessários investimentos em sondas, responsáveis pela varredura do solo em busca de reservas geológicas de petróleo e investimentos na própria perfuração, onde novas tecnologias devem ser desenvolvidas conforme o aumento da dificuldade de perfuração, seja ela oriunda da posição do poço ou de sua profundidade.

Nesse contexto, em 1963, foi criado o Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello, o CENPES, vinculado à Petrobras, que teve como primeiro grande feito a descoberta do Campo de Guaricema, em Sergipe, primeiro campo marítimo a ser explorado por uma plataforma marítima construída no Brasil, nomeada P-1, com capacidade de perfuração de até 4 mil metros de profundidade (ANP, 2019).

As Figuras 1–2 a seguir mostram o avanço tecnológico na perfuração no decorrer dos anos, que atinge distâncias cada vez maiores tanto em relação à lâmina d’água (Figura 1) quanto à profundidade total do reservatório, considerando o nível do mar (Figura 2).

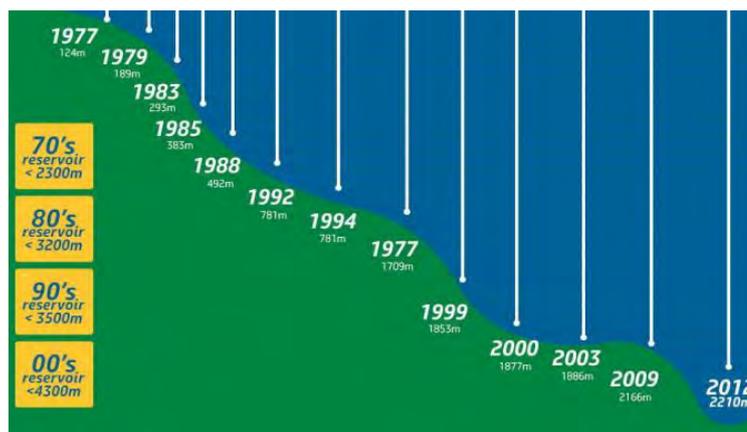


Figura 1. Profundidade alcançada na perfuração ao longo dos anos.  
Fonte: PETROBRAS, 2012.

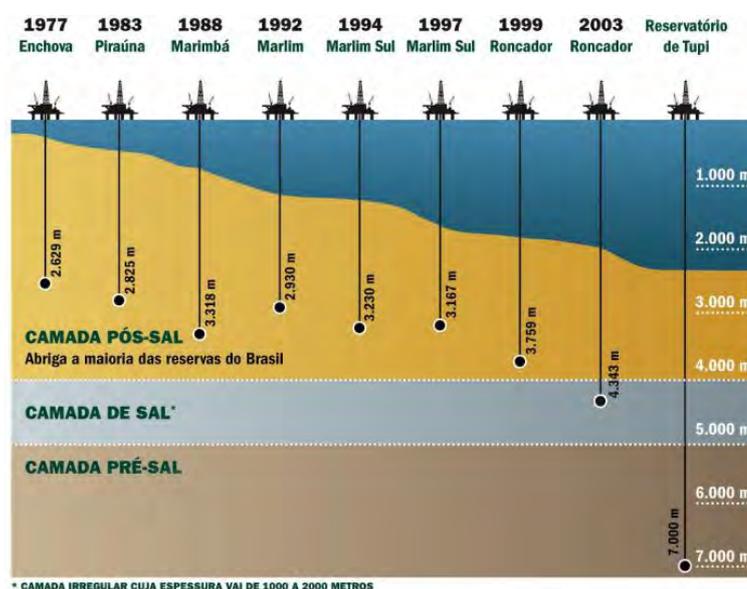


Figura 2. Profundidade total dos principais poços brasileiros.  
Fonte: PETROBRAS, 2010.

Um marco importantíssimo para o rumo das tecnologias aplicadas a perfuração foi a descoberta do pré-sal, nome dado à região calcárea localizada abaixo da camada de sal, a cerca de 7.000 m de profundidade. O primeiro campo, denominado Tupi, foi anunciado em 2007 e é a maior reserva já encontrada no país, contendo cerca da metade de todo o petróleo brasileiro. O impacto dessa descoberta fez com que o Brasil chegasse ao patamar de exportador de óleo (MBP COPPE, 2014).

É inegável que a exploração do pré-sal inclui obstáculos não antes existentes: os custos aumentam quanto mais profundos e longe da costa são os poços e a camada de sal, imediatamente anterior a camada do pré-sal, é considerada instável, devido a sua fluidez e às condições de altas pressões e temperaturas. Tudo isso faz com que o processo seja mais caro, demorado e demande tecnologias mais sofisticadas. Isso levou ao desenvolvimento de novos equipamentos, técnicas e fluidos de perfuração (DA SILVA, 2016).

#### 4.1.2 O processo de perfuração

No cenário atual, o método mais utilizado pelas indústrias é o de perfuração rotativa. Como o nome sugere, as formações rochosas são trituradas pelo peso e rotação aplicados pela broca na extremidade da coluna de perfuração, que caminha em direção ao poço.

Os fragmentos de rocha, denominados cascalhos, são levados à superfície pelo fluido de perfuração. Esse fluido é injetado no interior da coluna e retorna pelo espaço anular carregando os cascalhos gerados. Além dessa aplicação, o fluido de perfuração também tem função lubrificante para a broca e atua auxiliando na limpeza e estabilidade do poço (MATHIAS, 2016).

Depois de um determinado trecho perfurado, a coluna é retirada e é iniciado o processo de cimentação. Na cimentação, um tubo de aço de diâmetro um pouco maior que a broca é introduzido no poço e o espaço anular entre esse tubo e as paredes do poço é cimentado, permitindo o avanço da perfuração com segurança. O próximo passo é conectar uma outra broca, com diâmetro menor que o do revestimento e repetir o processo até a chegada ao reservatório. A etapa de cimentação, ainda que parcial, é de grande importância porque protege as paredes do poço, evitando problemas como o desmoronamento e a contaminação de lençóis freáticos. É útil, ainda, para impedir a migração de fluido pelas paredes do poço e sustentar a coluna de revestimento (CHIPINDU, 2010).

Com o aumento da profundidade e conseqüentemente da complexidade da perfuração, a ocorrência de problemas operacionais se torna mais frequente, motivando estudos que desenvolvam novas tecnologias aplicáveis ao processo, como brocas PDC (*polycrystalline diamond compact*), aprimoramento de fluidos de perfuração, técnicas de perfuração direcional e sistemas de monitoramento.

A implementação de sensores e sistemas de coleta de dados proporcionou a medição e registro de informações a respeito de parâmetros operacionais e características geológicas, permitindo a tomada de decisões durante o processo de perfuração, o que é fundamental para a intervenção mais rápida em casos de anormalidades e instabilidades, assim como para a mudança na trajetória do poço em casos de dificuldade de avanço.

Os principais sistemas geradores de dados de perfuração são: boletim diário de perfuração (BDP), com a descrição das atividades das últimas 24h pelo representante da empresa operadora; *mud-logging*, responsável pelos sensores instalados na sonda, realizando também a análise litológica a partir do cascalho; *measuring while drilling* (MWD), que monitora a trajetória do poço a partir de sensores instalados na broca; *logging while drilling* (LWD), responsável pela perfilagem da formação geológica durante a perfuração; e *pressure while drilling* (PWD), que monitora a pressão no fundo do poço, seja ela estática ou dinâmica de circulação (TAVARES, 2006).

#### 4.1.3 Problemas na perfuração de poços de petróleo

Problemas na perfuração de poços podem colocar em risco a integridade das instalações, dos operadores e do meio ambiente, além de ocasionarem tempo não produtivo. O primeiro passo é identificá-los para que não cresçam e tenham conseqüências maiores.

Alguns trabalhos se propuseram a identificar problemas operacionais, dentre eles, cita-se Idawa (1990), que avalia a prisão de coluna a partir dos esforços de torque e arraste nas movimentações de coluna e revestimento interno do poço. Cardoso Junior (1992) deu seqüência ao estudo anterior, propondo um sistema computacional de monitoramento de manobras, com o objetivo de diagnosticar problemas de perfuração. Nele, são identificadas algumas causas para o desmoronamento, fechamento, má limpeza de poço, chaveta, prisão de coluna, batentes e

alargamentos. Tavares (2006) propõe a detecção precoce de problemas de perfuração a partir de dados observáveis na superfície, como a redução/aumento da vazão de retorno, ou o aumento do torque, do arraste e da pressão de bombeio, que ocasionam perda de circulação, desmoronamento e alargamento de poço e influxos indesejados. Falcão et al. (2007) apresentam em seu estudo a possibilidade de fechamento de poço em formações salinas. A seguir são descritos, resumidamente, os principais problemas encontrados no processo de perfuração de poços e suas consequências:

Tabela 1. Problemas no processo de perfuração de poços. Fonte: Adaptado de TAVARES, 2006.

<b>Problema</b>	<b>Definição</b>	<b>Causa / Consequência</b>
<b>Perda de Circulação</b>	Perda total ou parcial de fluido de perfuração para a formação rochosa.	Pressão na parede do poço com valor maior que a pressão de fratura ou que a pressão de poros da formação. Ocasiona nível de fluido de perfuração dentro do poço reduzido e possível desmoronamento do poço.
<b>Prisão de Coluna</b>	Deposição de sólidos na região anular.	Ocorre após uma parada para manobra devido ao fluido de perfuração fora das condições necessárias ou ao desmoronamento de poço.
<b>Desmoronamento de Poço</b>	Queda de fragmentos da formação após a passagem da broca de perfuração.	Pressão da formação maior que a pressão interna do poço ou pressão interna não suficiente para conter uma formação não consolidada. Ocasiona alargamento de poço e prisão de coluna.
<b>Alargamento de Poço</b>	Aumento não desejado no diâmetro do poço.	Desmoronamentos localizados e influxos de fluidos. Prejudica a qualidade da cimentação, ocasiona “topadas” na descida e dificulta operações de pescaria.
<b>Má limpeza do Poço</b>	Acúmulo de cascalho no espaço anular.	Velocidade de fluxo inferior a velocidade mínima de carreamento de cascalho; uso de fluido inadequado; excessiva taxa de penetração, com produção de cascalhos numa taxa maior que a de remoção. Pode resultar em <i>packer</i> hidráulico e prisão de coluna.
<b>Packer Hidráulico</b>	Obstrução do espaço anular.	Acúmulo de cascalhos ou inchamento da formação que se expande com a hidratação, levando à prisão de coluna e ao fechamento de poço.
<b>Kicks</b>	Influxo de fluido da formação para o poço.	Pressão interna do poço é insuficiente para manter os fluidos da formação na rocha. Pode ocasionar desmoronamento e alargamento de poço. Se não for controlado, pode se tornar um <i>blowout</i> , erupção do poço.
<b>Fechamento do Poço</b>	Obstrução ou estreitamento do poço	Formação reativa ao fluido de perfuração, inchamento da formação ou movimentação de zonas de sal.

Dentre os problemas apresentados, muitos podem ser identificados em superfície e estão relacionados à vazão de cascalho que retorna do poço na lama, que pode ser aumentada, como em casos de desmoronamento, por exemplo, ou diminuída, em prisão de coluna. Além disso, o desmoronamento ocorre quando a pressão dentro do poço não é suficiente para sustentar a formação rochosa perfurada, fazendo com que parte das paredes internas se desprendam, seja pela ação mecânica da coluna ou por pouca coesão da formação. Nesses casos, o cascalho desmoronado tem formato diferente do cascalho perfurado, já que não demonstra evidências de impacto da broca (CHIPINDU, 2010).

Para identificar tal fenômeno é necessário separar o cascalho do fluido, o que é feito pelo sistema de controle de sólidos. Outras motivações para a separação são o descarte do cascalho dentro das especificações ambientais vigentes, além da possibilidade do fluido ser reinjetado no poço, aumentando a viabilidade econômica (PETRI JÚNIOR, 2017).

#### 4.1.4 Sistema de controle de sólidos

O sistema de controle de sólidos é formado por um conjunto de equipamentos e operações capazes de remover o maior número de partículas antes que o fluido seja reinjetado no poço, já que os sólidos não removidos terão seu tamanho reduzido a cada passagem pela broca, até que não seja mais possível a remoção. Seu objetivo é reduzir os custos de perfuração e minimizar a perda de fluido aderido aos cascalhos.

A composição do sistema de controle de sólidos depende do tipo de solo perfurado e do fluido de perfuração utilizado. Petri Júnior (2017) cita em seu trabalho que os principais equipamentos de um sistema brasileiro são degaseificador, peneiras vibratórias, tanques de decantação, hidrociclones, centrífugas e secadores, esquematizados na Figura 3 a seguir.

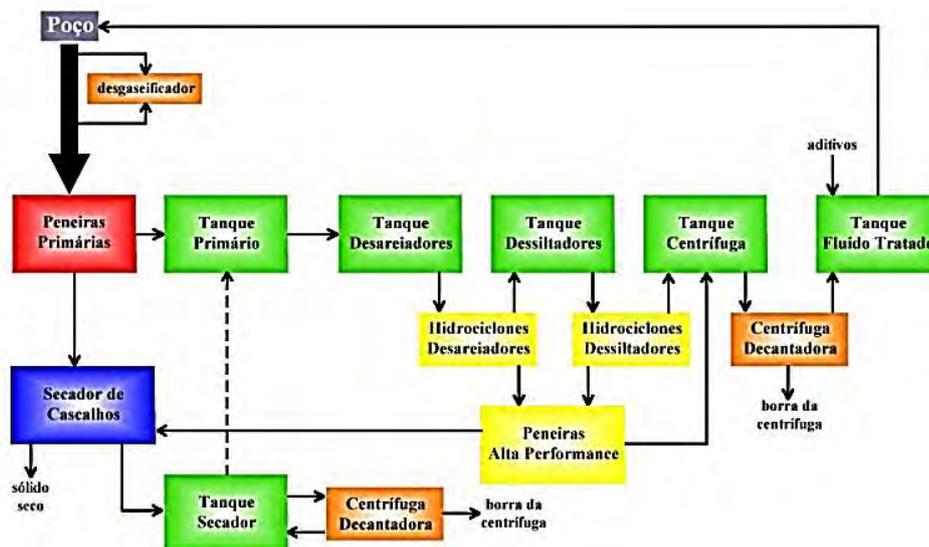


Figura 3. Esquema de um sistema de controle de sólidos brasileiro.

Fonte: PETRI JÚNIOR, 2017.

A primeira técnica de controle de sólidos era aplicada a poços terrestres e utilizava como ferramenta a ação da gravidade. Mais tarde, em 1930, foram introduzidas as peneiras vibratórias, projetadas a partir da tecnologia das indústrias de mineração e estas são consideradas, até hoje, os equipamentos mais importantes do sistema de controle de sólidos.

As peneiras vibratórias, também chamadas *shale shaker*, são equipamentos projetados para serem os primeiros a receber a lama, sendo assim, seu correto dimensionamento evita a

sobrecarga dos equipamentos seguintes do sistema. Devem ser capazes de processar todo o volume de lama que circula para fora do poço, possuindo a menor abertura possível para cada trecho de perfuração (PEREIRA, 2013). A vibração imposta, responsável pela queda das partículas e rápida separação, pode ser: elíptica, com inclinação negativa e menor tempo de retenção; circular, sem inclinação e permitindo o uso de múltiplas telas verticalmente empilhadas; ou linear, com inclinação positiva e uso de telas mais finas (PETRI JÚNIOR, 2017).

As telas utilizadas possuem abertura de 10 a 40 *mesh* para poços rasos e intermediários e 200 *mesh* para poços profundos. Para esse último caso, sólidos de tamanho superior a 74 micrômetros precisam ser removidos devido ao alto custo do fluido de perfuração utilizado no processo. Há, em etapa mais avançada do processo, a peneira vibratória de alto desempenho, chamada *mudcleaner*. É a responsável por remover partículas finas não removidas pelo hidrociclone e sua tela tem abertura que varia de 200 a 400 *mesh* (FAGUNDES, 2018).

O foco do presente trabalho é a identificação de problemas na perfuração a partir da análise de imagens do cascalho. Como mencionado anteriormente, são nas peneiras vibratórias que a separação se inicia, portanto, o estudo será direcionado para a identificação, classificação e análise do material sólido separado por este equipamento.

## 4.2 Cascalho de Perfuração

O termo cascalho refere-se a fragmentos de rocha produzidos pela broca durante a perfuração e carreados para a superfície. Sua correta identificação é fundamental para o entendimento da história deposicional e reconhecimento dos indícios de presença de hidrocarbonetos (FAGUNDES, 2018).

Apesar da definição abrangente, a ABNT definiu, com a NBR 6502/95 – Rochas e Solos, que cascalho é o nome dado a partículas de rochas com formato arredondado ou semi-arredondado de tamanho entre 2,0mm e 60mm. Essa norma classifica as rochas de acordo com sua origem, coloração, textura, composição química, tipo de rocha e propriedades químicas e mecânicas.

Além dessas características é necessário considerar a ação da broca utilizada na perfuração, que gera fragmentos de tamanho e forma regulares dependendo da formação e do tipo de broca utilizado. Essas duas últimas características são levadas em consideração para a escolha da abertura da malha das telas das peneiras (FAGUNDES, 2018).

### 4.2.1 Sistema mud-logging

O sistema *mud-logging* é responsável por duas importantes atividades: o monitoramento dos parâmetros de perfuração, através de sensores localizados na sonda que medem parâmetros mecânicos e hidráulicos; e a análise litológica do cascalho que chega às peneiras (TAVARES, 2006).

Os dados na medição dos parâmetros de perfuração são exibidos na cabine *mud-logging*, um contêiner localizado na sonda. Nela há telas de monitoramento e equipamentos de análise química, e podem enviar os dados a centros de controle localizados em qualquer parte do mundo. Para a caracterização litológica, amostras das peneiras são coletadas a cada intervalo de tempo e enviadas à cabine *mud-logging*, onde um geólogo realiza os ensaios de caracterização (FAGUNDES, 2018).

#### 4.2.2 Análise de cascalhos

Propriedades do cascalho, como a distribuição de tamanho e forma, podem indicar o início de algum problema na perfuração, portanto, uma boa análise é indispensável para justificar decisões e propor melhorias no processo. A metodologia utilizada pode ser definida em quatro etapas: amostragem, pré-tratamento, ensaios de caracterização e avaliação de resultados para classificação.

A etapa de **amostragem** consiste em coletar uma parte do cascalho que sai do poço a intervalos de tempo determinados. É feita a cada nove horas para zonas de baixo interesse e três horas em zonas de alto interesse, entretanto, os intervalos podem ser menores em casos de observação de mudanças nas características do fluido ou parâmetros de perfuração (FAGUNDES, 2018).

Uma questão interessante estudada por Karimi (2013) é a localização onde a amostragem será feita. O estudo aponta a falta de confiabilidade tanto para inspeção visual quanto para relatórios gerados das análises laboratoriais, uma vez que o material avaliado possa não ser representativo do material que sai do poço. Segundo o autor, apesar das amostras serem coletadas ao final da calha da peneira vibratória, esse não é o local mais indicado, porque as partículas mais finas já teriam passado junto ao fluido de perfuração. Esse tipo de amostragem pode indicar o desmoronamento do poço, que gera cascalhos maiores que o normal, mas não é capaz de identificar um volume anormal de cascalhos menores, que podem alterar as propriedades do fluido de perfuração, exigindo mais gastos com diluição, ou ainda problemas com a limpeza do poço. O local indicado pelo autor para melhor amostragem é na saída do poço, assim que entra no reservatório localizado acima das peneiras vibratórias.

O **pré-tratamento** é realizado em duas etapas: lavagem dos cascalhos em peneiras laboratoriais com jatos de água para a remoção do fluido de perfuração; e secagem com posterior armazenamento em sacos de algodão. São utilizadas duas peneiras, com telas de 2,38mm e 0,177mm. Os cascalhos retidos na primeira peneira são considerados de tamanho acima do normal, podendo representar cascalhos de desmoronamento, logo, são reservados para posterior caracterização litológica em busca da formação com possível instabilidade. Os cascalhos passantes na segunda peneira são considerados pequenos demais e são descartados. Somente os cascalhos retidos entre as duas peneiras são considerados para a distribuição do tamanho de partículas (FAGUNDES, 2018).

A **caracterização do cascalho** é o processo de obter informações que possam ser correlacionadas com as informações dos sensores de perfuração e informações adicionais, para ratificar a formação que está sendo perfurada. Um conjunto de características é avaliado e comparado a dados geológicos padrão, um manual com valores de referência e assim é possível identificar ou prever problemas durante a operação. As características avaliadas pelo geólogo na cabine *mud-logging* são basicamente forma, tamanho, textura, ocorrência, cor, brilho, dureza, porosidade, hidratação e composição mineralógica (FAGUNDES, 2018).

Inicialmente é feita inspeção visual com um microscópio estereoscópico para uma avaliação inicial do tipo de rocha e da textura. São avaliados também cor, brilho, clivagens e fraturas dos fragmentos. A seguir é feita a determinação da composição química do cascalho e caracterização mineralógica, de forma não destrutiva, sendo as principais técnicas utilizadas a fluorescência de raio-x e a difração de raio-x. A técnica utilizada para reunir o imenso volume de dados gerados em classes que representem cada formação geológica é a análise estatística multivariada, uma técnica de *clustering* (FAGUNDES, 2018).

A análise de distribuição do tamanho de partículas pode ser realizada a partir de algumas metodologias diferentes, dependendo da ordem de grandeza do material avaliado. Ordoñez (2015), em seu trabalho, mostra qual a técnica mais indicada para cada tamanho de partícula, informações dispostas a seguir, na Tabela 2.

Tabela 2. Técnicas aplicadas a cada tamanho de partícula.

<b>Técnica de Análise</b>	<b>Faixa de Tamanho de Partícula (<math>\mu\text{m}</math>)</b>
Peneiramento	100.000 – 37
Difração a Laser	2.000 – 0,1
Microscopia	1.000 – 0,1
Sedimentação	74 – 0,05
Método Couter	74 – 0,2
Espectroscopia de Correlação	3 – 0,003

Fonte: Adaptado de ORDOÑEZ (2015).

Levando em consideração que as partículas menores que 0,177mm são descartadas no pré-processamento, os métodos normalmente aplicados para análise granulométrica são peneiramento e difração a laser. O peneiramento, técnica mais utilizada, consiste na colocação de uma série de peneiras com abertura da tela em ordem decrescente de tamanho, com a amostra na primeira tela, a de maior abertura. É imposta vibração e as partículas menores caem para as peneiras inferiores até que sejam retidas por seu tamanho. A difração a laser avalia o quanto a luz de um laser, incidida sobre a partícula de cascalho, será desviada e a relação apresenta maior desvio quanto menor o diâmetro (ORDOÑEZ, 2015).

#### 4.2.2.1 Propriedades granulométricas e morfológicas

Os cascalhos possuem características dependentes da formação geológica e da broca utilizada na perfuração. A análise granulométrica permite estimar a distância percorrida por essas partículas desde a broca até a superfície, além de fornecer informações a respeito da composição do solo (MATTA, 2014). A Sociedade Americana de Engenharia Mecânica (ASME) classifica os sólidos em quatro grupos diferentes em relação a granulometria, enquanto a ABNT classifica em nove grupos. A Tabela 3 a seguir compara as duas classificações.

Tabela 3. Classificação de fragmentos de rochas pelo tamanho.

<b>Distribuição de Tamanhos (mm)</b>	<b>Classificação ASME</b>	<b>Classificação ABNT</b>
$d > 1.000$		Bloco de Rocha
$1.000 > d > 200$	Cascalho	Matacão
$200 > d > 60$		Seixo
$60 > d > 2$		Grânulo
$2 > d > 0,6$	Areia	Areia Grossa
$0,6 > d > 0,2$		Areia Média
$0,2 > d > 0,074$		Areia Fina
$0,074 > d > 0,06$	Lama	Areia Fina
$0,06 > d > 0,002$		Silte
$0,002 > d$	Colóide	Argila

Fonte: Adaptada de ALMEIDA NETO, 2017 e MATTA et al., 2014.

A morfologia tem influência na porosidade, permeabilidade e empacotamento da partícula, além de tornar possível a diferenciação entre um cascalho perfurado pela broca e outro oriundo de desmoronamento. Seus parâmetros descrevem as partículas

independentemente do tamanho e os mais comumente avaliados são arredondamento, angularidade, solidez, esfericidade e circularidade (ORDOÑEZ, 2015).

O arredondamento está relacionado à rugosidade superficial e à curvatura das arestas e vértices da projeção bidimensional da partícula e pode ser modificado pelo transporte e desgaste. A angulosidade é o inverso do arredondamento, representando a tendência de uma partícula a apresentar contorno angular. Em geral, a medida de arredondamento do cascalho aumenta com a profundidade, indicando o maior desgaste com o transporte. Outra característica é que o desvio padrão para essa variável ao considerar uma mesma região perfurada é pequeno, o que significa que se um cascalho com diferente angulosidade chega à superfície, ele provavelmente pertence a uma outra camada já anteriormente perfurada, indicando alguma instabilidade no poço (BARROS et al., 2007).

A medida de esfericidade representa o quão próximo do formato de uma esfera o fragmento de rocha se encontra. Para seu cálculo são necessárias informações a respeito do volume, portanto, para muitos casos essa propriedade é substituída pela circularidade. Esta última representa o quanto a projeção de um fragmento no plano bidimensional se aproxima de um círculo. Ambas têm seus valores variando entre zero e um (ORDOÑEZ, 2015).

A seguir são mostradas as equações utilizadas no cálculo do arredondamento e da circularidade, descritas por Ribeiro & Bonetti (2013).

$$\text{Arredondamento} = \frac{4\pi A}{p^2} \quad \text{Equação 1}$$

$$\text{Circularidade} = \frac{4A}{\pi(L)^2} \quad \text{Equação 2}$$

As medidas de arredondamento e esfericidade são variáveis independentes que podem ser combinadas para formar uma escala de classificação. Pode-se ainda correlacionar o arredondamento e a esfericidade com a porosidade do material.

Porosidade é a capacidade do material de armazenar fluidos em seu interior. Sendo assim, quanto maior a porosidade, maior a quantidade de fluido armazenada e conseqüentemente maior o volume de espaços vazios em seu interior que permitem a entrada de fluido. Essa propriedade também está relacionada com a densidade, que diminui à medida que o volume de poros aumenta. (SANSONE, 2014). A relação entre essas três propriedades pode ser observada na Figura 4.



Figura 4. Relação entre arredondamento, esfericidade e porosidade.

Fonte: SANSONE (2014).

Outro parâmetro possível de ser estimado é a solidez, que define a rugosidade aparente, textura do contorno da partícula. Ele é definido como a razão entre o perímetro e o diâmetro médio, inversamente proporcional à angulosidade. Esse parâmetro pode ser relacionado ao empacotamento de partículas, de forma que quanto maior a angulosidade, menor a solidez do solo e conseqüentemente mais pobre o empacotamento (ORDOÑEZ, 2015).

Almeida Neto (2017) diz ser possível classificar cascalhos sem análises laboratoriais, ressaltando que as características físicas e químicas são variáveis e dependem da geologia local, fluido de perfuração, técnica de perfuração e tipo de broca. Com os atuais avanços tecnológicos tem-se a possibilidade de determinar os parâmetros descritos na análise granulométrica e morfológica a partir de análise de imagens.

#### **4.2.2.2 Análise de imagens aplicada à determinação granulométrica e morfológica**

A técnica empregada para a avaliação de características morfológicas de fragmentos de rocha durante muito tempo foi a comparação visual com uma carta-padrão, um tipo de manual que verifica o grau de arredondamento e a textura superficial. Essa análise é realizada grão a grão, o que torna o processo muito lento e subjetivo, porque depende da capacidade de identificação e experiência do geólogo (ARAÚJO et al, 2015).

A popularização da fotografia digital, juntamente com o desenvolvimento de softwares de análises de imagens, abriu um novo horizonte na área de controle de processos, conferindo maior confiabilidade na estimativa de parâmetros em um menor tempo. As metodologias aplicadas nas análises são regulamentadas pelas normas: ABNT NBR 7809, para partículas maiores que 4,8mm, utilizando medição com paquímetro; e ISO13322-2/06, para menores que 4,8mm, por análise dinâmica de imagens (HAWLITSCHK et al., 2015).

Diferentemente das análises estáticas de imagem, onde o objeto de interesse é colocado sobre uma superfície ou lâmina de microscópio para ser avaliado, a análise dinâmica estima parâmetros geométricos a partir de imagens de fluxos de partículas. Alguns equipamentos foram projetados para fazer a caracterização baseada em análise dinâmica de imagens, como o QICPIC (Sympactec) e o CAMSIZER (Retsch Technology).

O QICPIC utiliza luz pulsada na faixa de nanosegundos para congelar opticamente as partículas enquanto uma câmera de alta resolução captura as projeções na frequência de 500 *frames* por segundo. As projeções passam por um processamento e as características de cada uma das partículas são calculadas. Sua faixa de operação é de 0,55 a 34.000 micrômetros com aplicação úmida e seca.

O CAMSIZER utiliza o mesmo princípio do equipamento anterior, mas com a diferença de utilizar duas fontes de luz pulsada e duas câmeras de alta resolução. Uma das câmeras tem ajuste para partículas pequenas e a outra para partículas maiores, ambas trabalhando a uma frequência de 60 *frames* por segundo e cada uma com iluminação própria. Sua faixa de operação é de 20 a 30.000 micrômetros com aplicação úmida e seca. A vantagem do sistema de câmera dupla é estatística: a alta precisão na medição para toda a faixa de operação. Partículas menores, que possuíam poucos *pixels*, passam a ter mais *pixels* em sua projeção, o que diminui o erro na estimativa. O sistema de câmera dupla descrito anteriormente pode ser melhor compreendido na Figura 5 a seguir.

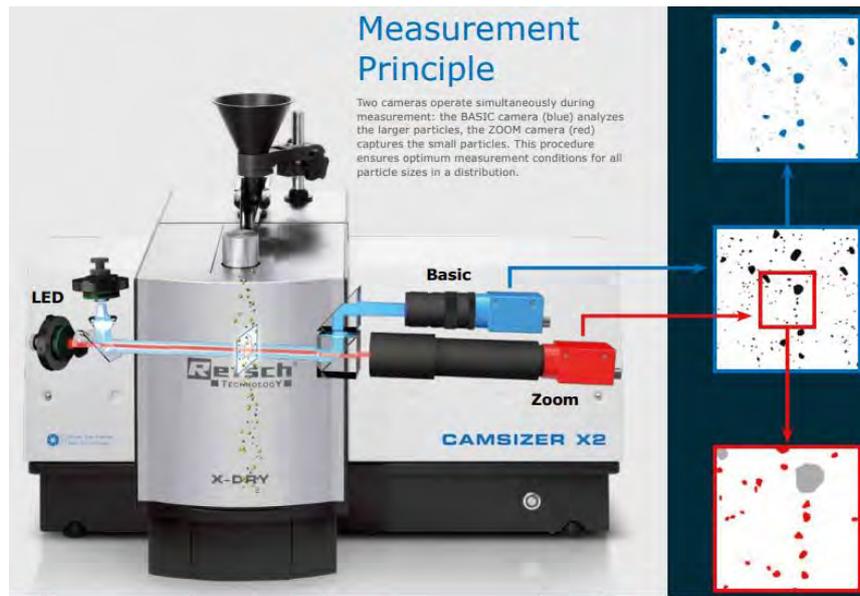


Figura 5. Sistema de câmera dupla do CAMSIZER.  
Fonte: RETSCH TECHNOLOGY.

Os dois equipamentos são muito úteis para a análise granulométrica e morfológica, entretanto, o cascalho fornecido ainda precisa receber pré-tratamento, o que faz dessa análise uma substituta da análise com peneiras. Além disso, os equipamentos fornecem medidas geométricas dos sólidos avaliados sem classificá-los, gerando um banco de dados que precisa ser trabalhado para fornecer de maneira aproveitável uma resposta às condições de perfuração.

Yu e Hancock (2008) propuseram em seu trabalho uma avaliação da capacidade de análise do equipamento QICPIC, descrevendo a distribuição do tamanho de partículas para dois tipos de celulose micro cristalina compactada: de formato esférico e de haste. Ao comparar a análise de imagem dinâmica com a resposta de um microscópio eletrônico de varredura observou-se a boa capacidade de medição, com resultados semiquantitativos.

Miller e Henderson (2010) mostram em seu trabalho uma aplicação para o equipamento Camsizer: avaliação da complexidade da forma de partículas de areia na construção de campos de golfe e afirma que essa ferramenta de análise fornece bons resultados para partículas complexas.

Como visto, apesar da boa resposta, esses equipamentos não são capazes de fornecer estimativas em tempo real numa linha de produção, independente do setor: eles são aplicáveis a sistemas de controle de qualidade.

Nesse sentido, a proposta desse trabalho é exatamente essa, utilizar o mesmo princípio de análise de imagens dinâmicas para a classificação granulométrica e morfológica do cascalho oriundo de poços de perfuração de petróleo, mas com duas diferenças: na aquisição da imagem que, de acordo com a proposta desse trabalho, será feita diretamente do processo; e na classificação, que será realizada por meio de algoritmos de inteligência artificial e de ferramentas de visão computacional.

Um exemplo que se aproxima do objetivo deste estudo foi proposto por Rabinski e Thomas (2004), que aplicaram a análise de imagens dinâmicas para a caracterização de partículas em suspensão, determinando a concentração e o tamanho das partículas em um fluxo contínuo no setor de águas. A avaliação contempla sólidos de 1,5 a 1.000 micrômetros e concentrações de 1 a  $10^6$  ppm e fornece também imagens estáticas para posterior análise. A metodologia aplicada desvia uma pequena amostra do fluxo de água para um capilar, onde uma câmera com luz óptica acoplada registra as partículas em escoamento. Trechos com material

particulado não permitem a passagem de luz, produzindo sombra e através desse mecanismo, aliado a escolha de um limiar de intensidade, são identificados os sólidos, o que permite a contagem. A concentração é calculada a partir do volume do capilar correspondente à janela de captura. A vantagem é que não é necessária nenhuma preparação das amostras, a aquisição é feita diretamente do processo. O trabalho não aborda nenhuma classificação do material analisado e o tempo para detectar e contar as partículas é de três minutos, considerado rápido, porém ainda não pode ser dito “tempo real”.

### 4.3 Visão Computacional

A Visão Computacional é uma tecnologia que tem como finalidade a automatização e integração de uma infinidade de processos através da extração de informações contidas em vídeos ou imagens, utilizando princípios do sentido biológico da visão. Foi teorizada no final da década de 1950, junto com o advento da Inteligência Artificial, mas tem tido aplicações crescentes nos últimos anos com o aprimoramento da capacidade de processamento dos computadores.

Alguns exemplos da versatilidade dessa técnica são citados a seguir: Martins (1999) propôs a calibração de padrões metrológicos; Souza e Marana (2004) propuseram o reconhecimento de pessoas em imagens de vídeos a partir de características biométricas, como altura e cor da pele; Frick (2008) propôs a caracterização de minério de ferro por análise de micrografia ótica, onde quatro características são extraídas das imagens (circularidade, razão de aspecto, razão de fibra e porosidade) e utilizadas para a classificação; Macedo (2012) propôs um sistema de auxílio ao diagnóstico de pneumonia através da análise textural de radiografias de tórax; Alexandre et al. (2013) propuseram o controle e navegação assistida de aeromodelos utilizando reconhecimento de padrões; Lima e Carvalho (2014) implantaram um sistema de controle de qualidade de agulhas em indústria farmacêutica baseado em visão computacional; Facco et al. (2017) propuseram o desenvolvimento de um sistema não invasivo de visão computacional capaz de estimar o tamanho de partículas de produtos granulares, aplicado a processos industriais; Borba Filho (2019) realizou um estudo sobre a automatização inteligente de pulverizadores de defensivos agrícolas para a redução de plantas daninhas, identificando áreas de maior vulnerabilidade.

O esquema mostrado na Figura 6 representa o algoritmo básico para o projeto de um sistema de visão computacional pontuando os principais aspectos de cada etapa.

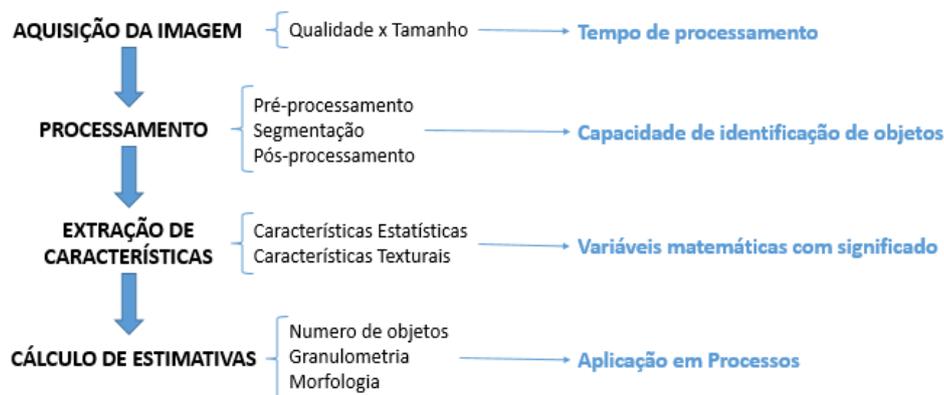


Figura 6. Passos para o projeto de um sistema de visão computacional.

Fonte: O autor.

A **aquisição da imagem** depende de fonte de radiação, seja do próprio objeto ou iluminação controlada do ambiente; instrumento capaz de capturar a cena em foco e resolução adequados, que no caso, seria uma câmera; e um sensor, ou conjunto deles, capaz de converter a radiação capturada em uma matriz de dados processáveis, a imagem digital (JIANG, 2001). Hoje esse passo é realizado por qualquer câmera digital. A imagem deve possuir qualidade suficiente para definir os objetos de interesse com precisão e não comprometer as etapas seguintes de detecção e cálculo de estimativas e tamanho pequeno o suficiente para reduzir o tempo de processamento e custo computacional.

O **processamento** inclui etapas de pré-processamento e pós-processamento, dependendo da qualidade da imagem adquirida e uma etapa de segmentação, que realiza a identificação dos objetos de interesse presentes na cena.

A **extração de características** tem a função de calcular parâmetros texturais da imagem e parâmetros geométricos dos objetos identificados na segmentação, que serão utilizados para a classificação e realização de estimativas aplicáveis a processos.

O conjunto final do sistema de visão computacional é responsável pela **classificação de padrões e atuação**. A tarefa de classificação tem como objetivo agrupar os objetos identificados de acordo com alguma semelhança. Os algoritmos de busca mais comumente utilizados tem como base conceitos de Inteligência Artificial e trabalham em duas fases: a primeira de treinamento, com um banco de dados pré-existente e a segunda de validação, com dados inéditos, que podem estar sendo medidos em tempo real. Para implementar a etapa de classificação de padrões é necessário entender um pouco a respeito de **Aprendizado de Máquina**. A atuação é a resposta do sistema em relação à análise realizada na etapa classificatória, que pode ser, por exemplo, a emissão de alertas sonoros e/ou visuais ao operador (GONÇALVES, 2010).

### 4.3.1 Processamento de imagens

#### 4.3.1.1 Pré-processamento e pós-processamento de imagens

Para que as características sejam extraídas de forma eficiente, estas precisam estar bem definidas na matriz de dados, o que muitas vezes exige etapas de melhoria da qualidade da imagem, seja com a restauração de informações perdidas, realce aspectos relevantes, ou com a remoção de ruídos. A essa etapa atribui-se o nome de pré-processamento. O pós-processamento é aplicado para corrigir pequenas falhas na segmentação e aumentar o realce para uma extração de características mais precisa (BALLARD & BROWN, 1892).

A filtragem digital é uma técnica amplamente utilizada nessa etapa e se fundamenta em uma operação de convolução entre filtros, conhecidos também como máscaras ou *kernels* e a imagem original (COSTA, 1998; ESQUEF et al., 2003). Há inúmeras possibilidades de defeitos decorrentes do processo de criação da imagem digital, portanto, existem inúmeras possibilidades para a correção deles. Na fundamentação teórica serão abordados os principais filtros utilizados na análise de imagens deste trabalho.

#### 4.3.1.2 Segmentação

A segmentação tem como objetivo, como o nome sugere, a segregação dos *pixels* em regiões por critérios de **descontinuidade** e **similaridade**. É considerada uma etapa crítica e determinante do processamento de imagens, uma vez que qualquer erro ou distorções na fragmentação são refletidos na etapa seguinte, de extração de características, podendo mascarar o resultado, ou torná-lo completamente sem sentido (ESQUEF et al., 2003).

Algoritmos que funcionam por **critério de descontinuidade** se baseiam em mudanças abruptas de níveis de cinza, sendo muito aplicados na identificação de padrões pela forma estrutural, como técnicas de detecção de pontos isolados e de bordas. Levam em consideração um limiar para fazer a busca pelas bordas. Quando um *pixel* com valor acima do limiar é encontrado, sua vizinhança é avaliada em busca de outros *pixels* com valores superiores ao do limiar e, então, a detecção segue na direção deste último *pixel*, tornando-o o *pixel* central e novamente avaliando a vizinhança. Ao longo do percurso, esses *pixels* são marcados como bordas da imagem e o algoritmo é interrompido quando a busca retorna a um *pixel* já marcado ou quando não houver mais *pixels* com valores superiores ao limiar na vizinhança, concluindo o contorno (COSTA, 1998). Em geral, precisam de várias etapas de pré e pós-processamento para apresentarem bons resultados e os algoritmos mais utilizados contam com a aplicação de filtros de *Sobel*, *Prewitt*, *Roberts*, entropia e *Hough*, por exemplo (SALDANHA & FREITAS, 2009).

Algoritmos que funcionam pelo **critério de similaridade** se baseiam na busca por características semelhantes entre objetos, como cor, contraste, intensidade de brilho e textura (BATISTA et al., 2010). As principais técnicas utilizam crescimento de regiões, que inicia a segmentação com um *pixel* ‘semente’ e incluem *pixels* vizinhos à medida que são detectadas intensidades semelhantes dentro de um desvio aceitável. Como exemplo pode-se citar o algoritmo *watershed*.

Há, ainda, mais uma abordagem, a segmentação no **espaço de atributos**. Os principais exemplos são: limiarização, que diferencia objetos e fundo de acordo com o histograma de intensidade de cores da imagem; e técnicas de *clustering*, ou agrupamento, onde o exemplo mais usual é o algoritmo *k-means*, que agrupa o conjunto de dados em *k* classes distintas de acordo com suas características (RONCERO, 2005; SALDANHA & FREITAS, 2009).

Existem inúmeras técnicas de segmentação, que funcionam de forma manual, com intervenção de um operador, ou de forma automática, com técnicas de inteligência artificial. Na fundamentação teórica serão abordadas as técnicas de segmentação utilizadas neste trabalho.

#### 4.3.2 Extração de características

A extração de características agrupa as informações de forma codificada no que se chama vetor de características, vetor de atributos ou assinatura. Este tipo de informação representa a essência da imagem segundo algum atributo específico, que pode ser a cor, forma, textura ou o relacionamento entre os objetos da imagem. A característica de um objeto é o atributo que nele se destaca de forma a distingui-lo dos demais objetos. Dessa forma, um conjunto de características define uma classe de objetos, formando o que se chama identificador, que deve manter sua proporção em casos de modificação de escala, rotação ou translação (BACKES, 2016).

Em seu trabalho, Rodenacker e Bengtsson (2003) apresentaram uma classificação das principais características de um objeto na imagem as dividiram em quatro grandes grupos: morfológicas, cromáticas, texturais e estruturais.

As características morfológicas consideram relevantes as informações a respeito da forma dos objetos, sendo mais utilizadas para o caso de imagens binárias. As cromáticas consideram as cores do objeto, ou a radiação emitida por ele, através da intensidade dos *pixels* em cada banda espectral. As características texturais diferenciam os objetos pela variabilidade na intensidade dos *pixels* totais da imagem, ou sejam, nos tons de cinza. E, por fim, as características estruturais, também conhecidas por características contextuais, descrevem a relação entre os objetos que compõem a imagem (BAUERMANN, 2008).

O presente trabalho tem como objetivo o estudo do escoamento do sistema cascalho/fluido de perfuração em peneiras vibratórias. Entretanto, outros tipos de sólidos foram estudados preliminarmente para realizar a prova de conceito e a validação das estimativas do aplicativo. Foram avaliadas características morfológicas e texturais, as mais relevantes e, em um caso, características cromáticas.

## CARACTERÍSTICAS MORFOLÓGICAS

As características morfológicas são utilizadas em estimativas de propriedades geométricas de cada um dos objetos identificados. Os descritores mais comuns são área, perímetro, diâmetro equivalente, centro de gravidade e comprimento do maior e menor eixo, mas podem ser calculadas até trinta propriedades diferentes a partir da função *regionprops* do software MatLab© (BACKES, 2016).

Essas características são muito representativas para a classificação e reconhecimento de padrões, uma vez que servem como parâmetro de entrada para o cálculo de propriedades como esfericidade, circularidade, tamanho médio de partícula, dentre outras.

## CARACTERÍSTICAS TEXTURAIS

As características texturais atuam por meio da percepção de variações locais nos valores de intensidade dos *pixels* da imagem, podendo ser regulares, na maioria dos casos de texturas artificiais, ou aleatórias, em grande parte das texturas naturais (SOUTO JUNIOR, 2010). Não existe um método universal de classificação de imagens por características texturais, entretanto, há três abordagens principais muito utilizadas em diversos trabalhos: estatística, estrutural e espectral (SCHWARTZ & PEDRINI, 2003).

A **abordagem estatística** descreve a textura através de medidas estatísticas da ocorrência espacial dos níveis de cinza. Em outras palavras, esta abordagem avalia a distribuição dos níveis de cinza e suas intensidades. Os descritores utilizados nessa abordagem podem ser de primeira ordem, quando avaliam individualmente a intensidade dos *pixels*, de segunda ordem, quando avaliam de forma correlacionada a intensidade e a posição espacial dos *pixels*, ou de ordens superiores (SILVA, 2007). Como exemplos de descritores, citam-se: para primeira ordem, histograma, média e variância e, para segunda ordem, correlações locais entre os níveis de cinza, onde o método mais aplicado é o das matrizes de co-ocorrência com descritores de Haralick (PAGAMISSE, 2004).

A **abordagem estrutural** caracteriza a textura utilizando uma estrutura mínima de repetição, também chamada primitiva, que tem formato regular e utiliza regras de posicionamento capazes de definir onde cada *pixel* se coloca em relação ao outro (PAGAMISSE, 2004). Seus descritores podem ser classificados como determinísticos, quando utilizam a forma absoluta dos *pixels* na imagem, ou probabilísticos, quando utilizam funções de probabilidade. Esta abordagem estabelece parâmetros como a conectividade, densidade e homogeneidade, mas é pouco utilizada, uma vez que poucas texturas apresentam a regularidade requerida na análise (SILVA, 2007; SOUTO JUNIOR, 2010).

Na **abordagem espectral**, a textura é relacionada a propriedades do espectro de Fourier, sendo utilizada na detecção da periodicidade global de uma imagem, ou seja, na identificação de picos de alta energia no espectro (SCHWARTZ & PEDRINI, 2003). Dessa forma, a textura é descrita no domínio da frequência e pela soma do conjunto específico de senos e cossenos utilizados na transformação de domínios. Uma técnica muito comum dessa abordagem é a decomposição por filtros de Gabor (SOUTO JUNIOR, 2010).

### 4.3.3 Técnicas de Inteligência Artificial

A inteligência artificial (IA) é uma área de conhecimento que tenta reproduzir em máquinas algumas características da inteligência humana, proporcionando a elas a capacidade de executar tarefas de forma aparentemente inteligente. A IA começou a ser explorada na Segunda Guerra Mundial e foi inicialmente classificada com o Teste de Turing, que avalia a capacidade de um computador ou algoritmo se passar por um ser humano em um interrogatório por escrito.

A inteligência está associada a competências como memória, percepção, imaginação, raciocínio e compreensão, sendo assim, é considerado dotado de inteligência aquele que possui a capacidade de aprender a partir de observações, de experiências e utilizar o conhecimento para identificar informações importantes e resolver problemas (GROSSI, 2017).

O que atribui tais competências aos computadores é denominado **aprendizado de máquina**. Seu objetivo é propor, através de modelos matemáticos não convencionais, algoritmos que resolvam problemas de classificação, regressão, agrupamento ou otimização. Esses modelos são propostos a partir de observações de um banco de dados e seus parâmetros são ajustados na etapa de aprendizado, também conhecida como treinamento. De forma geral, o algoritmo deve responder de forma adequada ao receber um estímulo de entrada e essa habilidade é conseguida após um bom treinamento (HORTA, 2015).

Outro objetivo que se deseja alcançar é a capacidade de adaptação à novas características apresentadas ao sistema sem que seja necessário desenvolver um novo código (ALMEIDA, 2018). Tanto a segmentação quanto a classificação e reconhecimento de padrões podem ser automatizadas utilizando técnicas de inteligência artificial.

#### ALGORITMOS DE APRENDIZADO SUPERVISIONADO

O aprendizado supervisionado utiliza vetores de treinamento, também chamados vetores de características ou atributos rotulados, para o ajuste dos parâmetros do modelo. Isso significa que para cada conjunto de estímulos de entrada fornecido durante o treinamento existe uma resposta, uma classe, de valor conhecido que representa a resposta ideal do modelo. O valor estimado pelo algoritmo é comparado com a saída pretendida por uma espécie de ‘professor’, que calcula o erro e ajusta os parâmetros da função para receber o conjunto de dados seguinte (PRATI, 2006; HORTA, 2015).

Esse tipo de treinamento tem como objetivo encontrar a função capaz de realizar previsões de respostas a partir de entradas desconhecidas ao algoritmo. Para isso é preciso o treinamento com um grande volume de dados, de forma que a função tenha boa capacidade de generalização para a previsão com precisão (ALMEIDA, 2018).

Exemplos de algoritmos de aprendizado supervisionado são árvores de decisão, classificação de Naive Bayes, regressão linear de mínimos quadrados, regressão logística, máquina de suporte de vetores e redes neurais artificiais.

#### ALGORITMOS DE APRENDIZADO NÃO-SUPERVISIONADOS

O aprendizado não supervisionado utiliza vetores de treinamento não rotulados, ou seja, somente estímulos de entrada para o ajuste do modelo. Seu funcionamento se baseia na busca de padrões que possuam alguma relação de similaridade, formando grupos e não realiza ajuste do modelo baseado na correção de erros (HORTA, 2015; ALMEIDA, 2018). Como exemplo podem ser citadas técnicas de *clustering*, decomposição em valores singulares, análise de componentes principais e análise de componentes independentes.

#### ALGORITMOS DE APRENDIZADO SEMI-SUPERVISIONADOS

O aprendizado semi-supervisionado é uma mistura dos dois outros tipos de aprendizado abordados anteriormente, sendo assim, utiliza vetores de treinamento rotulados e não rotulados, o que melhora consideravelmente o desempenho em relação aos algoritmos não-supervisionados (ALMEIDA, 2018). Nesse algoritmo os dados rotulados são utilizados na aprendizagem, para a otimização, enquanto os dados sem rótulo podem ser úteis na inserção de informações novas ao processo (HORTA, 2015).

Detalhes sobre o funcionamento e implementação dos algoritmos utilizados nas etapas de segmentação e classificação serão abordados na fundamentação teórica.

#### 4.4 Trabalhos Relacionados à Análise de Cascalhos por Imagem

O cascalho da perfuração de poços de petróleo pode fornecer informações importantes para o monitoramento do processo e indicar instabilidades no poço. Com os avanços tecnológicos, principalmente no segmento de inteligência artificial, estão sendo propostos estudos direcionados à identificação e análise do material a partir de técnicas de processamento de imagem e visão computacional.

##### Guyot et al., 2004

Uma tecnologia de visão com a função de determinar o tamanho de rochas on-line em correia transportadora, denominada *VisioRock*, foi proposta por Guyot et al. (2004) para aplicação na indústria de mineração, podendo ser utilizada tanto individualmente quanto integrada a um sistema de controle avançado.

A proposta é estudar objetos em movimento rápido, portanto, algumas configurações são essenciais no *hardware* para aquisição da imagem: uma câmera que consiga capturar imagens a 30 *frames* por segundo, permitindo estudos com movimentos em velocidades relativamente altas; obturador de alta velocidade, com abertura preferencialmente maior que 1/1.000 s; menor tempo de exposição, com iluminação mais potente, o que minimiza distorções de movimento (GUYOT et al., 2004).

O processamento de imagem possível dentro do aplicativo abrange a filtragem digital, segmentação, remoção de fundo, remoção de pequenos ruídos, estimativas da distribuição do tamanho de partículas, desdobramento 2D-3D e reconhecimento do tamanho de partículas por textura. Todos eles são escolhidos automaticamente pelo *software* de forma que o processamento se ajuste às condições da imagem fornecida. As principais variáveis calculadas são a distribuição do tamanho de partículas, histograma de cores RGB e HSV, características texturais e parâmetros estatísticos. Como resultado o aplicativo exibe a imagem original ao lado da imagem processada, com os objetos identificados destacados em cores, que variam de acordo com o tamanho da partícula. Na Figura 7 é possível visualizar a interface do programa desenvolvido. Ainda é possível emitir alertas personalizados de acordo com os resultados obtidos (GUYOT et al., 2004).

Os autores não especificam os algoritmos utilizados em cada etapa, mas apontam para a utilização de alguns módulos: de lógica *fuzzy* integrada a um bando de dados, como núcleo do aplicativo; sensores com modelos preditivos adaptativos, para o ajuste automático de filtros e escolha do melhor algoritmo de segmentação de imagens; um módulo que utiliza redes neurais que permite o aprendizado adaptativo de acordo com novos dados apresentados na planta; e um módulo genérico que permite inclusão de algoritmos, caso seja de interesse do usuário.

O monitoramento online de partículas sólidas em esteiras é fundamental em processos da indústria de mineração e vem ganhando espaço na indústria de petróleo, com a possibilidade de

prevenção de acidentes e redução de custos a partir do monitoramento do cascalho de perfuração.

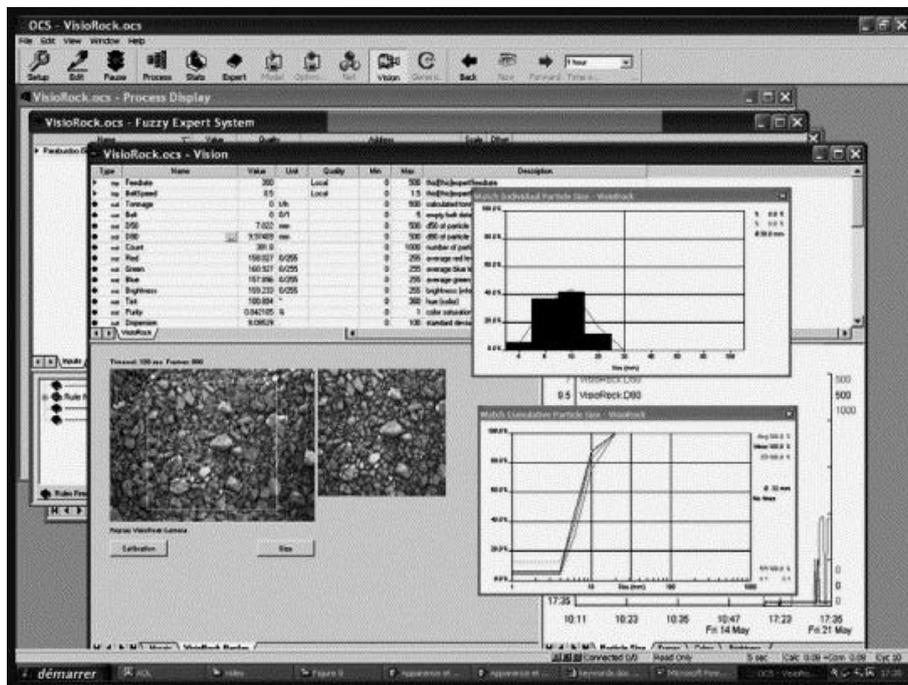


Figura 7. Interface de análise do *VisioRock*.  
Fonte: GUYOT et al., 2004.

### **Marana et al. (2009)**

Marana et al. (2009) propuseram um sistema inteligente que utiliza técnicas de visão computacional para monitorar o processo de perfuração de poços através de análises de imagens de cascalho. Antes disso, as técnicas utilizadas para o monitoramento nessa indústria levavam em consideração somente as informações já coletadas pelos sensores instalados no *mud-logging*.

A metodologia aplicada avalia quadro a quadro do vídeo fornecido por uma câmera digital, que registra o escoamento em peneira vibratória, identificando o volume de sólidos e enviando alertas para que o operador verifique e até intervenha na perfuração em caso de anomalias. Foram utilizados quatro classificadores supervisionados para com este propósito baseados em floresta de caminhos ótimos (OPF), redes neurais artificiais do tipo *perceptron* de múltiplas camadas (ANN-MCP), máquina de suporte de vetores (SVM) e classificador bayesiano (BC) (MARANA et al., 2009).

As imagens retiradas dos vídeos foram rotuladas de acordo com três classes: E, para nenhum sólido na peneira; L, para baixa concentração de sólidos; e H para alta concentração de sólidos. As imagens de treinamento e teste para todos os classificadores foram obtidas manualmente, de forma aleatória, num total de 40 amostras para cada classe, sendo destas, 20 para treinamento e 20 para teste. A classificação adotada está exemplificada na Figura 8 .



(A) (B) (C)

Figura 8. (A) Classe E; (B) Classe L; (C) Classe H.

Fonte: MARANA et al., 2009.

Os algoritmos propostos não realizam a detecção de objetos, sendo a classificação feita a partir de quatro características texturais de Haralick. Para o caso do classificador OPF, cada nó do grafo contém um vetor com quatro variáveis, correspondentes à energia, entropia, homogeneidade e contraste. Para a ANN-MCP, foram utilizados 4 neurônios na camada de entrada, representando as características mencionadas, 19 neurônios na camada intermediária, representando o número de vetores de treinamento subtraído de uma unidade e 3 neurônios na camada de saída, representando as 3 classes.

Foi avaliada a precisão média de cada um dos classificadores implementados e o tempo médio de execução da classificação. Todos apresentaram bom desempenho, porém, dentre os resultados obtidos, o melhor foi o OPF, com precisão média de 99,85% e tempo de 0,0023s (MARANA et al., 2009).

### **Guilherme et al., 2010**

Na sequência deste trabalho, foi proposta a otimização para o classificador OPF implementando um novo classificador: OPF Eficiente (EOPF) (GUILHERME et al., 2010).

Para projetar um OPF é necessário primeiro definir a conectividade entre os grafos e escolher heurísticamente os protótipos, as sementes, que representam as classes. Em seguida, com o treinamento, cada protótipo pode agregar à sua classe um grafo próximo, pela lógica do crescimento de regiões. Na fase de teste, o que define a qual classe um determinado grafo irá pertencer é a função custo, que calcula a distância para cada um dos vértices presentes no caminho de determinada classe. O rótulo é atribuído à classe que possui o caminho ótimo, de menor custo (SILVA, 2016).

A melhoria alcançada com o classificador EOPF é a minimização da função custo, que aumenta a precisão e diminui o tempo de classificação. Foi observado que essa melhoria pode fazer com que este classificador seja 6 vezes mais rápido que o OPF propostos no primeiro trabalho (GUILHERME et al., 2010).

### **Guilherme et al., 2011**

O mesmo grupo de pesquisa deu continuidade ao trabalho incluindo estimativas do volume de sólidos em tempo real, utilizando a técnica de regressão de vetores de suporte (SVR) e funções de ajuste (FF). As amostras foram divididas em quatro classes, que correspondem a 0%, 50%, 75% e 100% de sólidos presentes no recorte. Novamente foram utilizados os recursos de Haralick como dados de entrada tanto para o treinamento quanto para o teste. Em relação aos resultados obtidos, o algoritmo foi capaz de realizar classificações com erros médios quadráticos de 0,007609 e 0,008356 para SVR e FF, respectivamente (GUILHERME et al., 2011).

### **Liao et al., 2010**

Em paralelo, outro estudo apresenta um sistema de varredura *on-line* capaz de estimar o tamanho e a forma de partículas sólidas utilizando processamento de imagens com desvio de  $\pm 1\%$ . O erro relativo à sobreposição é reduzido, uma vez que a aquisição da imagem é feita em uma zona de queda vertical de sólidos, com um desvio de 1% (LIAO et al., 2010).

Diferente dos trabalhos anteriores, são estimadas características morfológicas ao invés de texturais, o que só é feito com precisão pelo fato das partículas serem registradas individualmente pela câmera, sem agrupamento ou sobreposição.

O processamento envolve a binarização por limiar simples, seguida de inversão das cores da imagem, para então extrair as características dos objetos identificados. É aplicado filtro de preenchimento de regiões e a técnica de mesclagem para analisar partículas que estão incompletas nas bordas. O processamento descrito (Figura 9) e a técnica de reconstrução (Figura 10) são mostrados a seguir. Para essa última, é utilizada uma sequência de *frames* da queda para estimar a borda ausente da partícula.

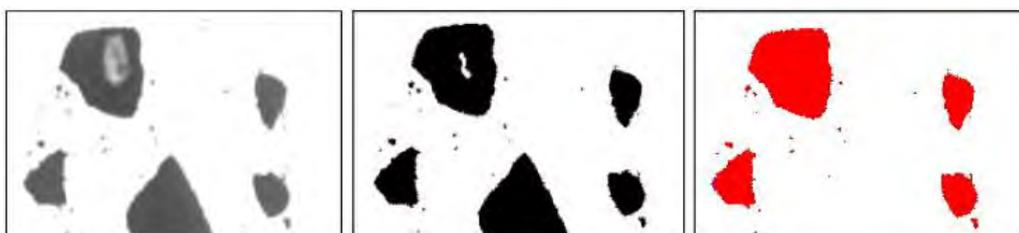


Figura 9. Processamento de imagens do sistema de varredura.  
Fonte: LIAO et al., 2010.

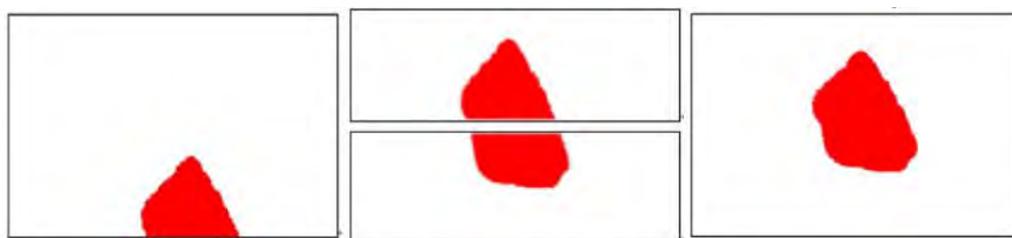


Figura 10. Reconstrução de objetos com bordas incompletas.  
Fonte: LIAO et al., 2010.

A análise de partículas é feita pela aproximação do objeto a uma elipse, de acordo com as medidas de seu centroide e raios máximo e mínimo. As propriedades de área e o volume são estimados pela área da elipse equivalente e o volume do esferoide oblato equivalente, o que permite estimativas de circularidade e esfericidade. Também foi estimado o peso das partículas com base em sua densidade, variável previamente conhecida. O sistema foi testado, com repetibilidade, para areia, esferas e partículas com formato irregular, obtendo excelente desempenho nas estimativas (LIAO et al., 2010).

### **Ko & Shang, 2011**

Ko & Shang (2011) propuseram a criação de um *soft sensor* baseado em redes neurais artificiais (ANN) capaz de fornecer a distribuição do tamanho de partículas em tempo real, usando análise de imagens de minérios. Apesar de não se tratar do estudo de cascalho de perfuração, as imagens obtidas podem ser comparadas às imagens do problema proposto, onde partículas maiores representam a variação de cascalhos ascendentes do poço e as partículas muito finas, o fluido de perfuração, ambos com a mesma coloração.

A metodologia aplicada divide a imagem RGB em cinco regiões de mesmo tamanho, no formato de cruz, nomeadas como: superior (T), central (C), inferior (B), esquerda (L) e direita (R) e em seguida, é aplicado o limiar no valor 130 para operação de binarização, sem nenhum pré-processamento adicional. Essa divisão aumenta o banco de dados e possibilita uma melhor avaliação da homogeneidade da imagem. Na sequência é calculada a uniformidade da imagem, baseada em análise de textura e esta é a variável de entrada da ANN proposta.

A rede possui duas camadas escondidas, cada uma com quatro neurônios e a camada de saída fornece a classe de tamanhos a qual a imagem pertence. Os minerais são divididos em 3 classes, ilustradas na Figura 11 e o tamanho real dos sólidos em cada classe é estimado pelo software de mineração WipFrag©, que também o faz utilizando processamento de imagens, mas ajustando a medida à equação de *Rosin-Rammler*. Com essas estimativas e as medidas de uniformidade, é realizado o treinamento supervisionado da ANN segundo o algoritmo *Levenberg-Marquardt*. Segundo o autor, a relação entre o número de partículas e a uniformidade é altamente não linear, entretanto a ANN proposta é capaz de fornecer uma estimativa confiável mesmo no caso de partículas muito grandes, onde há sobreposição. (KO & SHANG, 2011).

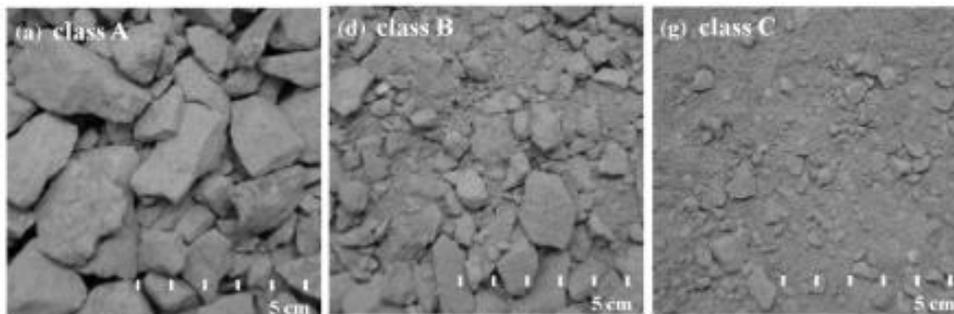


Figura 11. Classes de minerais classificados pela ANN.

Fonte: KO & SHANG, 2011.

As técnicas mencionadas anteriormente, exceto o proposto por Liao et al. (2010), fazem uso da análise textural, que avalia a imagem como um todo pela matriz de co-ocorrência de níveis de cinza. A vantagem dessa abordagem é que sem o processamento de imagens a classificação do volume de sólidos se torna rápida, porém não é possível obter nenhuma informação morfológica a respeito do cascalho.

### **Serapião et al., 2011**

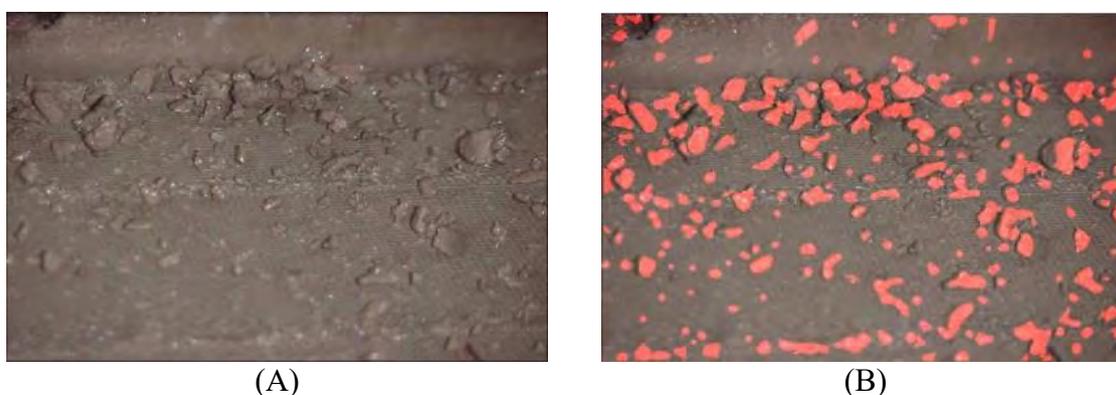
Alguns trabalhos se propuseram a estudar essas características e aplicaram técnicas de processamento de imagens na simulação do escoamento de cascalho em peneira em condições controladas. Um estudo importante foi realizado por Serapião et al. (2011), que além do processamento propuseram a detecção dos sólidos a partir de técnicas de visão computacional utilizando como ferramenta de apoio o *software LabView*.

A metodologia experimental aplicada consistiu em realizar simulações de um protótipo de peneira vibratória mantendo a condição operacional e variando o ângulo de aquisição da imagem e a iluminação local. O algoritmo converte, inicialmente, a imagem adquirida para níveis de cinza e na sequência, realiza uma série de operações de realce e remoção de ruídos. Elas incluem, nessa ordem, o ajuste de contraste, aplicação de filtros passa baixa, média e mediana, equalização histogrâmica, subtração de fundo e mais um ajuste de contraste. Após o pré-processamento, é realizada a binarização por limiar simples, calculado a partir do método de *Otsu*. É realizada também uma etapa de pós-processamento, que inclui as técnicas de

dilatação e erosão, que preenchem buracos presentes no interior dos objetos e realizam a separação de sólidos conectados, respectivamente. A detecção do cascalho foi realizada pela técnica de visão computacional conhecida como *Blob Coloring*, ou detector de bolhas (SERAPIÃO, et al., 2011).

O termo *blob* se refere a componentes de uma imagem binária conectados entre si, portanto, o algoritmo *blob coloring* funciona da seguinte forma: os *blobs* são detectados na imagem por um procedimento de limiarização; na sequência, são conectados com outros *blobs* vizinhos e semelhantes, formando o objeto e a saída do algoritmo fornece as coordenadas x e y do contorno de cada objeto identificado; a técnica fornece ao final a imagem com os objetos detectados em cor vermelha (GALLON, 2013).

Como resultado foi apresentada a sobreposição da imagem original (Figura 12A) e a resposta à detecção (Figura 12B), com resultados que os autores consideram satisfatórios diante das dificuldades apresentadas no processamento de imagens. A proposta seguinte seria melhorar o passo de processamento e detecção dos cascalhos antes de seguir para a etapa de classificação, mas não foram encontrados indícios de sequência desse trabalho.



(A) (B)  
Figura 12. (A) Imagem original; (B) Resultado do *Blob Coloring*.  
Fonte: SERAPIÃO et al., 2011.

### **Khorram et al., 2011**

Outro estudo, realizado por Khorram et al. (2011), utiliza uma rede neural para estimativa da composição de minério em uma mina do Irã através de análise de imagens, sendo muito útil para controle de qualidade. O trabalho não está relacionado com análise de cascalho de perfuração, mas utiliza técnicas interessantes de inteligência artificial para definir quais são as características mais relevantes para a classificação das pedras, o que pode ser considerado e aplicado no presente trabalho.

A aquisição da imagem foi feita em ambiente controlado, em seguida, foi aplicado filtro de mediana para remoção de ruídos e por último, a binarização. Foram extraídas 76 características de cada imagem, sendo elas morfológicas, texturais e de cor, compondo um vetor de alta dimensão. Pelo elevado custo computacional, foi conduzida uma análise de componentes principais (PCA) para escolha das mais relevantes, revelando 6 componentes principais, que foram utilizados como entrada para a rede neural proposta. A saída da rede foi composta por 4 neurônios, cada um representando a concentração de um componente. O treinamento foi supervisionado e as correspondências de concentração para cada imagem foram obtidas através de testes químicos de laboratório.

Como resultado foi possível obter um ajuste de 80% de correspondência entre dados reais e dados estimados (KHORRAM et al., 2011). Apesar disso, vale ressaltar que as imagens são oriundas de um processo de mineração, onde os sólidos são limpos antes de serem fotografados

e as cores presentes neles são muito significantes. Essas condições não podem ser comparadas à condição do cascalho, embebido de fluido de perfuração, que passa pela peneira vibratória sem apresentar valores significantes de contraste ou diferença de cor.

### **Kistner et al., 2013**

Em outro trabalho, Kistner et al. (2013) propuseram o monitoramento de uma esteira rolante com partículas de carvão em tamanho variado utilizando análise imagens. O objetivo é classificar o tamanho das partículas em três grupos, de acordo com a porcentagem de finos presente em cada um deles. A Figura 13 exemplifica o tipo de partículas em cada classe.

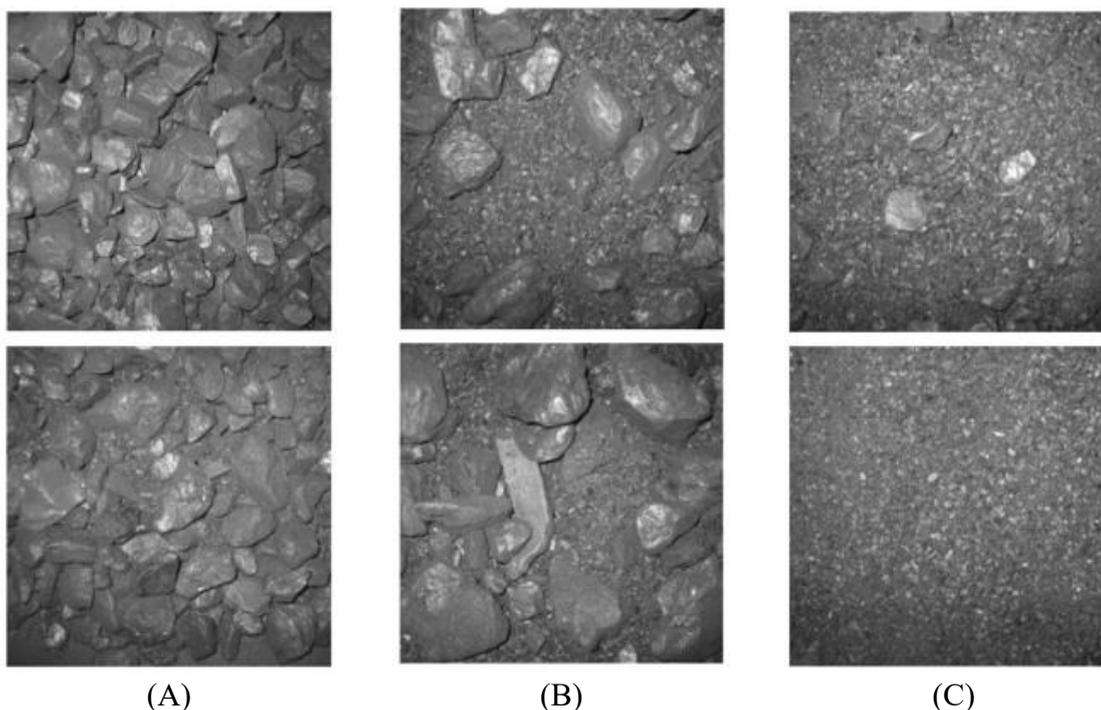


Figura 13. Amostras das três categorias de tamanhos de partículas. (A) 0 – 20% de finos; (B) 40 – 60% de finos; (C) 80-100% de finos.

Fonte: KISTNER et al. (2013).

O estudo foi direcionado a aplicações em reatores de leitos fluidizados, que tem restrições quanto a alimentação de partículas muito finas de catalisador, entretanto, essas imagens possuem certas semelhanças com imagens de cascalho coletadas em peneiras vibratórias, onde o contraste e a diferença de cor entre cascalho e fluido, representados por partículas grandes e finos, é mínimo.

São propostos três algoritmos, utilizando, cada um, quatro técnicas para a classificação segundo recursos texturais: análise discriminante linear (LDA), análise discriminante quadrática (QDA) e k-vizinhos mais próximos (*k-nn*). As técnicas abrangem o uso de matrizes de co-ocorrência, transformadas de *wavelets*, pirâmides direcionáveis e visão computacional (KISTNER et al., 2013).

A metodologia com matrizes de co-ocorrência utilizou as características de energia, contraste, homogeneidade e correlação, calculadas para 4 direções (0, 45, 90 e 135) e entropia, formando um vetor de 17 recursos para cada imagem. Para as transformadas de *wavelets*,

realizou-se a decomposição em sete níveis e para cada nível avaliou-se a característica de energia nas direções vertical, horizontal e diagonal, formando um vetor de 21 recursos. As pirâmides direcionáveis utilizam um conjunto de 4 estatísticas capazes de capturar características texturais: estatísticas marginais; correlação bruta entre coeficientes; magnitude do coeficiente; e fase em escala cruzada. A aplicação requer a especificação do número de escalas, de orientações e o tamanho da vizinhança espacial sobre a qual os descritores serão calculados, com os valores 4, 5 e 9, respectivamente, levando a um vetor de 1.044 recursos. Para o classificador que utiliza visão computacional, foi utilizado um banco com 13 filtros rotacionalmente invariantes e 15 *clusters* foram definidos a partir do algoritmo *k-means* (KISTNER et al., 2013).

Dentre os classificadores propostos o que obteve melhor desempenho foi o QDA baseado em técnicas de visão computacional, com erro de 4,3%. O classificador apresentou precisão nas estimativas quando o foco não está na distribuição detalhada de grãos, mas sim nas proporções entre partículas grandes e finos (KISTNER et al., 2013).

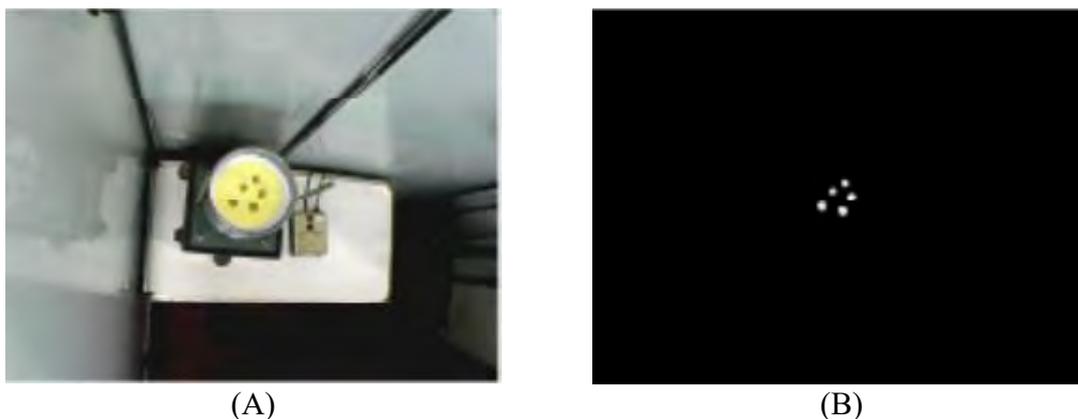
### **Matta, 2014**

Matta (2014), realizou um estudo de caracterização de particulados em fluido de perfuração baseada em processamento digital de imagens. Para isso utilizou dois sistemas diferentes de peneiras vibratórias: o primeiro composto por peneiras laboratoriais, analisado pelo *software* MatLab©; e o segundo por uma esteira, analisado pelo software LabView™. Os algoritmos utilizados no processamento são iterativos e o usuário pode escolher qual caminho seguir de acordo com sua visualização.

Os ensaios em peneira laboratorial, além de não representarem o escoamento de sólidos, fizeram com que todos se aglomerassem. A estratégia adotada para este equipamento foi utilizar somente as grades, sem vibração, com colocação manual dos sólidos de maneira dispersa. Em um segundo momento, optou-se pela aquisição de imagens de uma esteira, que representa o movimento do cascalho, mas também sem vibração (MATTA, 2014).

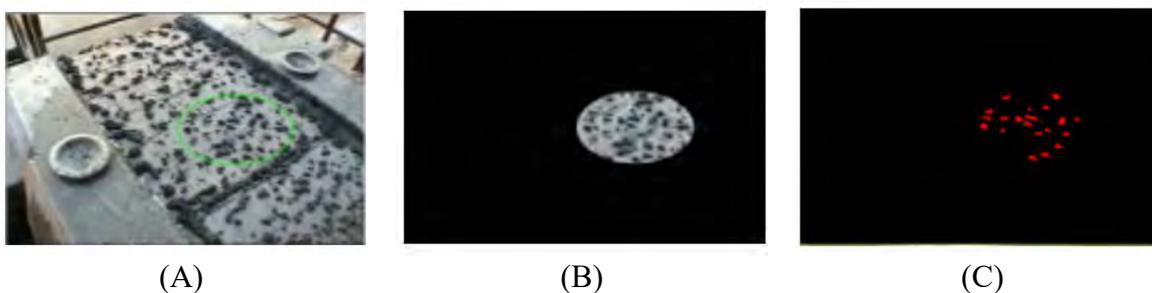
O algoritmo desenvolvido com o software MatLab© compreende a seleção da ROI; calibração da imagem com uma imagem de calibração, caso seja pretendido obter resultados em unidades reais; e conversão para imagem em tons de cinza. Na sequência podem ser ajustados os seguintes parâmetros: conectividade; inversão de cores; *threshold*; utilização de filtros, com a definição de tipo, ordem e quantidade de vezes consecutivas em que serão aplicados; e modo de operação, com processamento de uma única imagem ou contínuo.

Um exemplo de resultado do processamento proposto pode ser visto na Figura 14, com a identificação do cascalho na peneira laboratorial. Esse algoritmo foi capaz de realizar a contagem de objetos e o cálculo da área média. Em relação a contagem, o máximo de 17% é observado para casos de reflexão de luz e eventuais aglomerados. Em relação a área, foi observado um erro de 9% para sólidos regulares de  $1\text{cm}^2$ , que representa a medida de 2 *pixels*, o que pode ser atribuído à distorção, apesar da calibração, do objeto pela lente da câmera (MATTA, 2014; MATTA et al.1,2014).



(A) (B)  
 Figura 14. (A) Imagem original; (B) Objetos identificados.  
 Fonte: MATTA, 2014.

O algoritmo desenvolvido com o software *LabView* se restringiu à identificação e contagem dos sólidos. A etapa de processamento inclui a conversão para imagem em tons de cinza, a seleção de uma ROI e duas opções de filtragem: manipulação de contraste, brilho, gama e aplicação de filtro de mediana, ou convolução com matriz de destaque de detalhes. Deste ponto em diante tem-se três caminhos possíveis: aplicação de filtro de *Sobel* + binarização + preenchimento de buracos internos aos objetos + rejeição de objetos tocando a borda; ou binarização por limiar comum + rejeição de objetos tocando a borda + filtragem de área e fator de alongação; ou binarização por limiar local de *Niblack* + rejeição de objetos tocando a borda + filtragem de área e fator de alongação. Um exemplo de resultado obtido é mostrado na Figura 15 (MATTA, 2014 | MATTA et al.<sup>2</sup>,2014 | MATTA et al.,2015).



(A) (B) (C)  
 Figura 15. (A) Imagem original; (B) ROI; (C) Objetos detectados. Fonte: MATTA, 2014.

O autor defende que os resultados foram satisfatórios, mas ainda são necessários ajustes para um melhor processamento. De fato, aglomerados de cascalho foram descartados, gerando um erro de 23% na contagem e dependendo da escolha do usuário, pode não ser detectado nenhum sólido, o que torna esse algoritmo não muito eficiente. O índice de acerto desse aplicativo foi de 61% (MATTA, 2014).

O trabalho apresentado realiza uma série de operações no processamento de imagens, o que torna o processo de identificação e classificação muito lento. Além disso, a escolha por um algoritmo que permite a interatividade retoma a necessidade de um operador qualificado, distanciando o procedimento da automatização. Apesar disso, é um estudo de grande relevância pela avaliação quantitativa dos sólidos na imagem.

**Cipelli et al., 2014**

Cipelli et al. (2014), complementaram o trabalho anterior com a ferramenta LabView, realizando o cálculo da área média das partículas na esteira. Outra diferença, ilustrada na Figura 16, é que a imagem original foi submetida a transformações geométricas antes da seleção da ROI. Essa modificação aumentou a taxa de acerto para 89%.

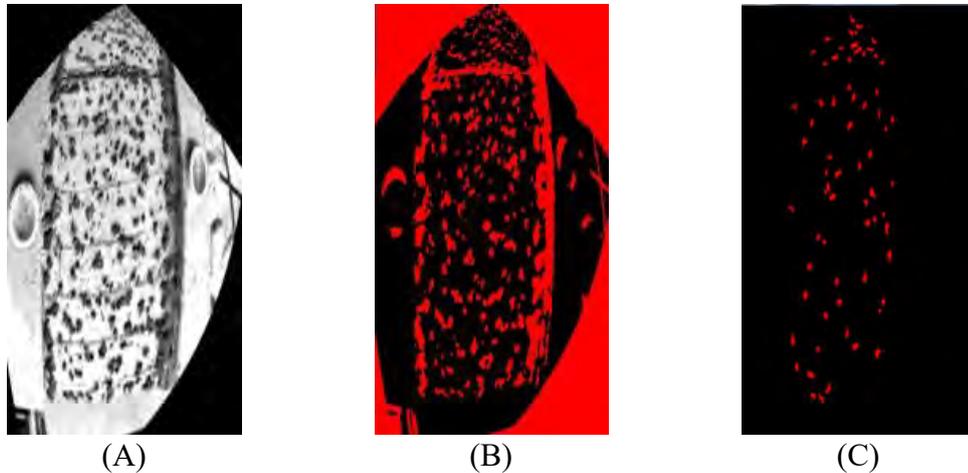


Figura 16. (A) Imagem de referência; (B) Imagem binarizada por limiar comum; (C) Imagem final, após processamento.  
Fonte: CIPELLI & ASSIS, 2014.

### **Hamzeloo et al., 2010**

Um trabalho interessante que realiza análise de imagens dinâmicas foi proposto por Hamzeloo et al. (2014), que estudaram a aplicação de técnicas de processamento de imagem e redes neurais artificiais para estimar, em tempo real, o tamanho de partículas em uma correia transportadora de um concentrador de cobre no Irã. O principal objetivo do estudo é determinar a precisão das redes neurais para tal tarefa e identificar quais características de tamanho possuem maior eficácia.

O processo envolveu a aquisição de 21 imagens que foram processadas manualmente, uma vez que não é objetivo do estudo propor uma nova forma de segmentação. Foram utilizados filtros de nitidez, Gabor, detecção de bordas, binarização por limiar simples e extração de características estatísticas, tudo com apoio da ferramenta MatLab©. O resultado do processamento pode ser visto na Figura 17 (HAMZELOO et al., 2014).



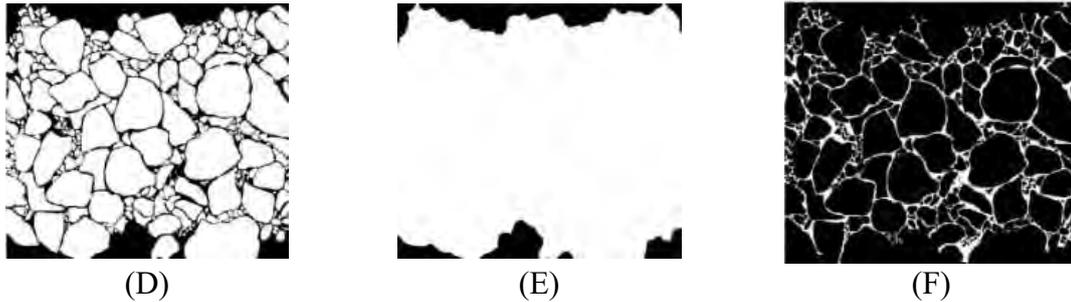


Figura 17. Processamento manual de imagens de pedras. (A) Imagem original; (B) borda aprimorada; (C) Imagem binarizada; (D) Imagem segmentada; (E) Região de partícula; (F) Imagens detectadas com precisão.

Fonte: HAMZELOO et al., 2014.

A distribuição real do tamanho de partículas foi encontrada a partir de peneiras de tamanho variando de 110mm a 5mm, informação necessária para o treinamento da rede. As principais características geométricas obtidas a partir da segmentação foram: área; perímetro; diâmetro do círculo equivalente; maior e menor eixo da elipse equivalente; medidas do menor retângulo que contém o objeto; diâmetro de *Feret*, que mede a distância entre duas tangentes de lado oposto da partícula a cada 1 grau, retornando 180 valores, onde o valor máximo representa o comprimento e o mínimo representa a largura; diâmetro do disco máximo capaz de ser inscrito em cada objeto (HAMZELOO et al., 2014).

Foram propostas duas maneiras de estimar o tamanho das partículas: diretamente, pelas características medidas e indiretamente, com a aplicação de análise de PCA e redes neurais artificiais do tipo *perceptron* de múltiplas camadas (ANN MLP). A arquitetura utilizada na ANN MLP foi composta por um neurônio de entrada, com a variável de maior importância segundo a PCA, duas camadas escondidas com 6 e 3 neurônios, respectivamente e uma saída, o tamanho da partícula (HAMZELOO et al., 2014).

Como resultado da estimativa direta, a variável que melhor estimou o tamanho da partícula foi a do maior círculo inscrito, mas ainda apresentou um desvio significativo. A estimativa obtida pela RNA teve desempenho superior, com resultados compatíveis com os obtidos na análise com peneiras (HAMZELOO et al., 2014).

### **Khojasteh et al., 2015**

Retomando o estudo de cascalho de perfuração, cita-se o trabalho de Khojasteh et al. (2015), que propuseram a detecção automática de formações geológicas em poços de petróleo no Irã baseada em análise de imagens e em máquinas de vetores de suporte (SVM). Características relacionadas à cor e textura e outras de média e covariância fornecidas pela clusterização com o algoritmo *fuzzy c-means* (FCM), são utilizadas pela SVM para a classificação dos sólidos em 5 grupos.

A aquisição das imagens é feita em ambiente com iluminação e temperatura controlada e como no estudo de Ko & Shang (2011), as imagens são divididas em outras de menor tamanho, mas dessa vez sem formato definido. A imagem original de tamanho 900 x 900 *pixels* é segmentada em 25 imagens 300 x 300, considerando sobreposição de 50% em todos os sentidos, o que aumentou significativamente o conjunto de dados de treinamento. A Figura 18 exemplifica a divisão e ilustra uma das camadas litológicas estudadas (KHOJASTEH et al., 2015).

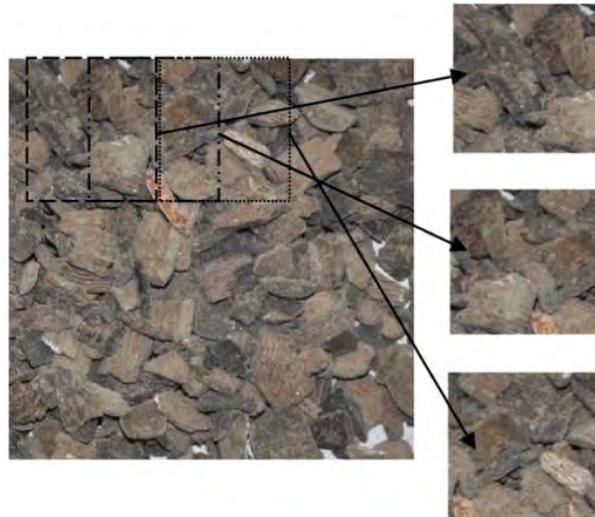


Figura 18. Representação da divisão da imagem original em 25 outras imagens.  
Fonte: KHOJASTEH et al., 2015.

Os resultados obtidos através do algoritmo FCM em combinação com a classificação baseada em análise de cores, mostraram desempenho máximo, 100% de acerto, no caso de três das cinco camadas litológicas estudadas e de 70% nos outros dois casos. Esses últimos representam o limite entre duas formações diferentes, portanto, é de interesse que esse desempenho seja otimizado para a melhor visualização da mudança de formação, que pode sinalizar a mudança de broca, por exemplo. Ao avaliar somente essas duas classes em outra SVM, utilizando imagens de 3 poços distintos, a precisão aumentou para 87,5% e o tempo médio de resposta para as classificações foi de 180 segundos (KHOJASTEH et al., 2015).

Para a análise textura, as imagens foram convertidas em escala de cinza e suas matrizes de co-ocorrência foram calculadas. As características texturais de Haralick utilizadas nesse estudo foram contraste, correlação, energia e homogeneidade. Como resultado, ao avaliar as 5 classes, foi obtido um desempenho variando de 44% a 92%, dependendo da classe estudada, sendo o desempenho mais baixo para as mesmas classes de baixo desempenho na análise de cores. Avaliando-as separadamente, a análise textural alcançou um desempenho de 95% e tempo de resposta médio de 32 segundos (KHOJASTEH et al., 2015).

Em resumo, este trabalho mostrou-se eficiente para a classificação das camadas geológicas, entretanto, os resultados obtidos servem como ferramenta ao trabalho do geólogo na cabine de *mud-logging*, uma vez que para obtê-los, é necessário inicialmente realizar a limpeza dos cascalhos, seguida de organização dos mesmo em uma superfície fotografável.

### **Yang & Chen, 2017**

Um grande problema na caracterização de sólidos em superfícies é a sobreposição, que impede a visualização das partículas inferiores. Yang & Chen (2017) propuseram um sistema de visão computacional capaz de estimar o tamanho e a forma de partículas, baseado em processamento de imagens, com capacidade de medição de agregados sobrepostos sem a necessidade de dispersão. Os autores destacam a importância da iluminação uniforme e constante para qualidade na detecção, o que diminui a complexidade no processamento. O aparato experimental de captura das imagens possuía iluminação artificial e uma placa preta de alta absorção de luz como fundo.

O processamento passou pelas seguintes etapas: filtragem por *kernel* de convolução para suavização; segmentação por limiarização, pelo método de *Otsu* para sólidos em queda e pelo

limiar de *Niblack* para sólidos na esteira; e operações de abertura e fechamento para melhor delimitação do contorno dos objetos (YANG & CHEN, 2017). Devido a iluminação uniforme, os parâmetros escolhidos inicialmente pelo desenvolvedor não precisaram ser modificados, o que possibilitou o funcionamento on-line do sistema sempre com o mesmo desvio médio nas medições.

O aplicativo avaliou sólidos em queda e sólidos passantes em uma esteira, sendo que o primeiro apresentou os melhores resultados: com erro de 3% para estimativas de tamanho e 2% para estimativas de forma. A análise em esteira apresentou desvios, por vezes, maiores que 10%, que estão diretamente associados à complexidade do processamento de imagens, uma vez que somente sólidos na superfície foram avaliados (YANG & CHEN, 2017).

### **Facco et al., 2017**

Outro trabalho de relevância para a análise de sólidos através de imagens foi proposto por Facco et al. (2017). Em seu trabalho, descrevem um sistema de visão computacional para estimar quantitativamente a distribuição de tamanho de produtos granulares utilizando análise de textura multivariada e multirresolução. Os autores defendem que a análise textural demonstra bom desempenho no dimensionamento de partículas sem a identificação explícita de forma individual. O trabalho é voltado para o controle de qualidade de materiais vendidos a granel, mas a metodologia aplicada tem potencial de aplicação para o estudo do cascalho oriundo de poços de perfuração de petróleo.

Os experimentos foram executados segundo planejamento experimental de forma a obter 6 lotes de material granular com distribuição de tamanho de partícula variada. Os lotes foram submetidos a peneiramento para separar os grânulos em quatro faixas de tamanho contíguas: A, de 600 a 800  $\mu\text{m}$ ; B, de 800 a 1.000  $\mu\text{m}$ ; C de 1.000 a 1.400  $\mu\text{m}$ ; e D, de 1.400 a 2.000  $\mu\text{m}$ . O resultado experimental do peneiramento é mostrado na Figura 19 (FACCO et al., 2017).

O sistema de análise de textural de imagem multivariada com várias soluções (AVS) realiza inicialmente o pré-tratamento das imagens, com o ajuste automático de contraste e aumento da homogeneidade da imagem a partir da decomposição por *wavelets Coiflet*. Também foi feita a subtração de sombras e compensação de não uniformidades. Observações indicaram que texturas mais finas, que apresentam resoluções e frequências de sinal mais altas, se relacionam com grânulos menores, enquanto texturas mais grossas, com resoluções e frequência mais baixas, representam grânulos maiores. As estimativas das frações são calculadas em uma mistura, com a calibração realizada por regressão multivariada e validada pelo método de Monte Carlo (FACCO et al., 2017).

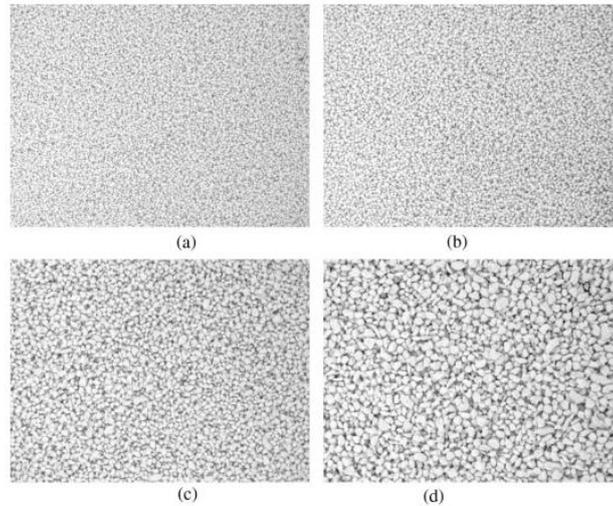


Figura 19. Distribuição granular (a) A; (b) B; (c) C; (d) D.  
Fonte: FACCO et al., 2017.

No método da decomposição de *wavelets*, a imagem é decomposta em quatro outras imagens, sendo uma delas a aproximação de baixa resolução da imagem e as outras três a imagem detalhada de alta resolução para as direções horizontal, vertical e diagonal. Essa decomposição foi realizada para 6 níveis de resolução diferentes.

A extração de características considera seis índices diferentes: média, desvio padrão, entropia, energia, assimetria e curtose. Aplicando seis índices para cada uma das quatro imagens de cada uma das seis resoluções determinadas, tem-se, para cada imagem original, um total de 144 características texturais compondo um vetor de análise.

Uma das complicações da caracterização é o fato de os intervalos serem contíguos, não havendo uma diferença nítida na transição entre uma faixa e outra. Outro fator é que as faixas possuem intervalos de tamanho diferentes, não regulares. Apesar disso, o maior desafio apontado pelos autores é a variabilidade da cena para uma mesma proporção de distribuição granulométrica, ou seja, se uma seleção de grãos é fotografada e posteriormente embaralhada, os grãos mudam de posição, levando a vetores de características diferentes, ainda que a amostra seja a mesma. Para minimizar esses fatores de erro são coletados um volume grande de dados para treinamento.

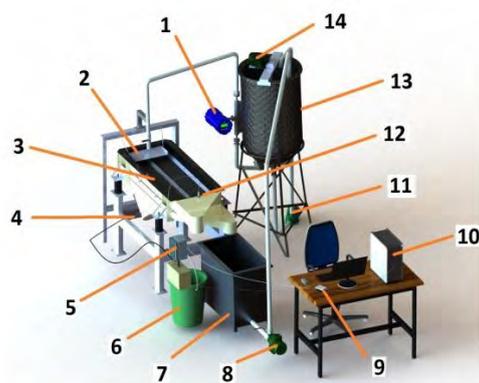
As frações A e B apresentaram maior dificuldade no cálculo da estimativa, com desvio menor que 10% em 69% dos casos para A e 82% para B e maiores que 20% em 4% dos casos para A e 0,8% para B. Isso pode ser explicado pelo tamanho pequeno das partículas, sendo representadas por um conjunto pequeno de *pixels*, o que aumenta significativamente o erro no caso de inclusão ou retirada de um *pixel* vizinho. Para a fração C a estimativa apresentou erro menos que 10% em 93% dos casos.

### **Silva, 2017**

Silva (2017) propôs a análise de imagem aplicada ao processo de peneiramento vibratório para avaliar a dinâmica de funcionamento da peneira. O estudo utilizou experimentos de um protótipo de peneira em escala piloto para avaliar aspectos do escoamento de sólidos com uma suspensão de areia padronizada com goma xantana a 0,1%. Os experimentos tiveram como proposta avaliar como algumas variáveis operacionais influenciam na porcentagem da área da tela ocupada por sólidos e o teor de umidade dos sólidos. O objetivo do estudo de Silva (2017) foi entender como as técnicas de análise de imagens podem ser aplicadas para obter informações qualitativas sobre as variáveis de saída.

A variável teor de umidade dos sólidos retidos é importante para a avaliação da eficiência do peneiramento e está diretamente relacionada à área de secagem. Sendo assim, quanto menor a área de secagem, maior o teor de umidade e consequentemente maior a perda de fluido de perfuração no processo de separação (SILVA, 2017). Apesar de não se tratar da análise de cascalho, o estudo tem grande relevância porque aponta outras variáveis que podem ser monitoradas por análise de imagens juntamente com o cascalho no controle do processo.

A unidade experimental utilizada por Silva (2017) está ilustrada na Figura 20. Os experimentos foram realizados segundo planejamento composto central  $2^k$ , totalizando 16 experimentos, considerando quatro variáveis independentes controladas: força-g aplicada à peneira, vazão de alimentação da suspensão, inclinação da tela da peneira e concentração volumétrica de areia. Os ensaios foram registrados em vídeos.



Componentes da bancada experimental:

1. Medidor de taxa mássica tipo Coriolis (CONTECH TCM028K);
2. Distribuidor de alimentação;
3. Peneira (Vibrocraft) com tela de 175 mesh (Tegape);
4. Motovibradores (VR4-07);
5. Inversor de frequência (WEG CFW700);
6. Recipiente de coleta de material retido;
7. Tanque de coleta de material passante;
8. Bomba de retorno do passante para o tanque de alimentação;
9. Placa de aquisição de dados (National Instruments USB 6008);
10. Computador (sistema de controle no software Labview®);
11. Bomba Recirculação/Alimentação;
12. Acelerômetro piezelétrico (PCB Piezoelectronic 646B00);
13. Tanque de alimentação – 300 litros;
14. Sistema de agitação mecânico;

Figura 20. Unidade experimental de ensaios com peneira piloto e suspensão de areia e goma xantana 0,1%.

Fonte: Adaptado de Barbosa (2018).

Dentre as imagens obtidas a partir dos vídeos das simulações, foram escolhidas as que representavam com maior clareza cada área da peneira ocupada para serem processadas pelo software *ImageJ*. O teor de umidade foi determinado experimentalmente.

O pré-tratamento das imagens incluiu o ajuste de contraste, intensidade e brilho, seguido da conversão da imagem para níveis de cinza. O passo seguinte consistiu na delimitação de uma região de análise, como mostra o polígono em vermelho na Figura 21<sup>a</sup>. Os objetos foram demarcados manualmente (Figura 21B) e, por fim, utilizou-se a binarização por limiar simples para segmentar a imagem (Figura 21C).

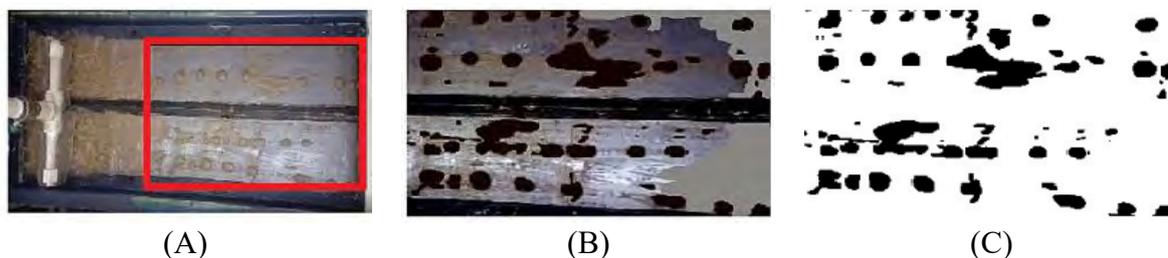


Figura 21. (A) Imagem original; (B) Recorte da região de análise; (C) Resultado do processamento de imagem.

Fonte: SILVA, 2017.

Em alguns casos não foi possível separar de forma satisfatória alguns aglomerados e, então, foi utilizada delimitação manual de regiões de interesse. O estudo mostrou que a análise

de imagens pode ser muito útil para avaliar condições operacionais das peneiras vibratórias (SILVA, 2017).

### **Barbosa, 2018**

Dando sequência ao estudo deste grupo de pesquisa, Barbosa (2018) propôs a realização de novos experimentos com um planejamento experimental diferente, o planejamento composto central  $3^k$ . As variáveis independentes utilizadas foram as mesmas do estudo anterior, força-g, vazão de alimentação da suspensão, inclinação da tela e concentração volumétrica de areia. Como variáveis de saída, além do teor de umidade e porcentagem da área da região de secagem preenchida por sólidos, foram também estimadas por análise de imagens a velocidade de escoamento na região de secagem e a área da região de piscina. A demonstração esquemática de como ocorre o peneiramento vibratório é mostrada na Figura 22, com a localização de cada uma das regiões citadas. Os vídeos registraram a vista superior da peneira.

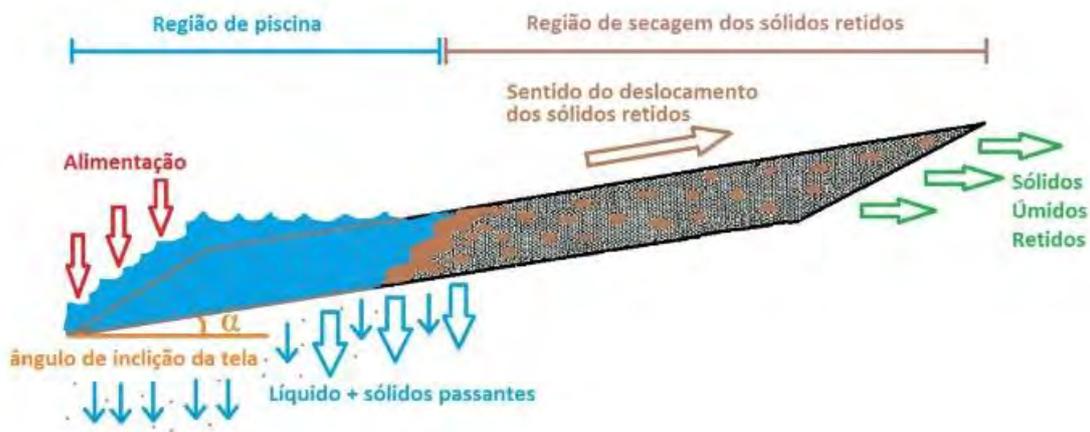


Figura 22. Exemplo esquemático do funcionamento da peneira piloto durante ensaios.

Fonte: Barbosa, 2018.

A área de piscina foi detectada manualmente por delimitação de regiões de interesse, mostrada em amarelo na Figura 23. A imagem foi então binarizada e somente a região delimitada foi considerada como um objeto válido para a contagem de pixels. A medida foi feita para 3 frames aleatórios durante todo o escoamento e a resposta foi obtida a partir da média dos três pontos. A conversão do número de pixels da área delimitada para unidades reais foi feita com auxílio de régua digital, que fez a relação entre um trecho de tamanho conhecido.



Figura 23. Resposta da detecção da área de piscina.  
Fonte: Barbosa, 2018.

Para a estimativa da área da região de secagem preenchida por sólidos utilizou-se a mesma técnica de detecção: delimitação de regiões de interesse para três frames aleatórios durante todo o escoamento. A porcentagem de preenchimento foi calculada como a razão entre a área ocupada por todos os sólidos detectados e a área total delimitada em laranja na Figura 24.



Figura 24. Detecção da porcentagem da área da região de secagem preenchida por sólidos.  
Fonte: Barbosa, 2018.

A velocidade de escoamento foi determinada também de forma manual, medindo o deslocamento de uma partícula sólida entre dois frames e dividindo pelo tempo de aquisição entre os frames. A medida também utilizou uma régua digital, ilustrada na Figura 25, e foi repetida seis vezes para todo o escoamento. A resposta final foi obtida a partir da média dos pontos.

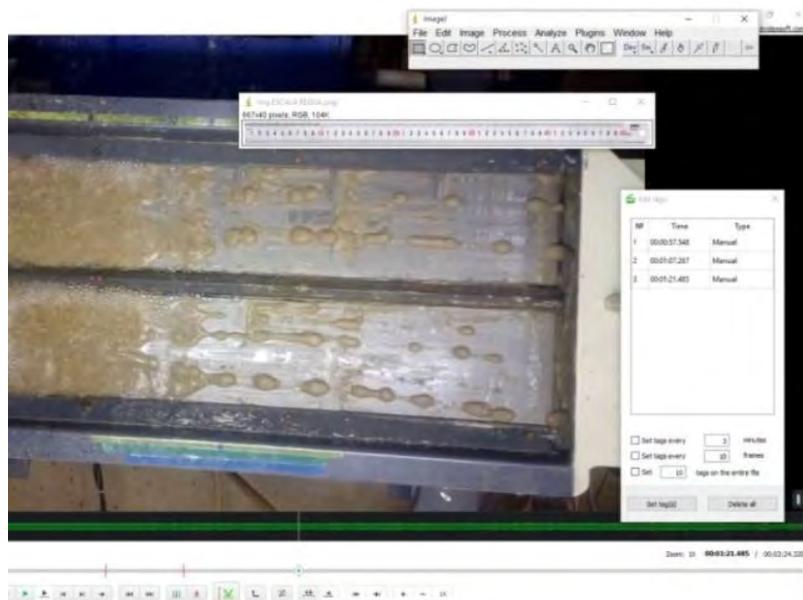


Figura 25. Ilustração do método de aferição de velocidade de escoamento.  
Fonte: Barbosa, 2018.

Segundo Barbosa (2018), a análise de imagens se mostrou eficiente para a determinação quantitativa das variáveis, facilitando a análise estatística que determina as condições ótimas de operação da peneira vibratória.

### **Yaghoobi et al., 2019**

Um estudo recente mostra avanços no reconhecimento de minérios. Yaghoobi et al. (2019) realizaram um estudo baseado em redes neurais e métodos de extração de características para propor um sistema de visão computacional capaz de estimar a distribuição do tamanho de partículas de minério no processo de fragmentação por jateamento.

A extração de recursos pode ser feita pela de transformada de Fourier, através da análise da imagem redimensionada dividida em anéis concêntricos; pela análise de *Wavelets*, com avaliação da imagem aproximada e seus detalhes, onde os níveis de resolução são definidos de acordo com sinais de entropia; pelos filtros de Gabor, utilizados para análise textural; ou pela combinação dos recursos mencionados anteriormente. Para todos os casos foram extraídos recursos de média e desvio padrão e não foi utilizado nenhum tipo de pré-tratamento na imagem. A rede neural proposta recebe como entrada os vetores de características extraídos, possui duas camadas intermediárias e uma camada de saída composta 10 neurônios, que representam as classes de minério estudados (YAGHOOBI et al. 2019).

O estudo apresenta como melhor resultado para a distribuição granulométrica de material o método da transformada de Fourier aplicada às redes neurais, com 67% de acerto nas estimativas. Além disso, é salientado que todos os métodos aplicados são superiores em relação ao modo automático do aplicativo comercial *Split-Desktop*, *software* mais comumente usado para a determinação da distribuição granulométrica a partir de técnicas de processamento de imagens (YAGHOOBI et al. 2019).

## 5 FUNDAMENTAÇÃO TEÓRICA

### 5.1 Imagem Digital

A imagem digital é definida como a representação bidimensional de uma cena real tridimensional. A formação da imagem ocorre com a conversão da energia luminosa emitida pelos objetos em cena, que pode ser oriunda do próprio objeto ou de iluminação artificial, em energia elétrica, gerando o sinal elétrico que posteriormente é convertido em sinal digital (JIANG, 2001).

Em outras palavras, a imagem digital é a distribuição da intensidade luminosa, para cada ponto do plano cartesiano em que a imagem se encontra, feita através da codificação dos sinais por números binários, onde cada algarismo recebe o nome de *bit* e pode assumir os valores 0 ou 1.

Fazendo uma analogia matemática, a cena real pode ser representada por uma função contínua, que tem como domínio o conjunto dos números reais. Um computador não é capaz de representar fielmente essa quantidade infinita de pontos e então utiliza a técnica de discretização para simular o comportamento da função contínua, a partir dos procedimentos de amostragem e quantização (SCURI, 1999).

#### 5.1.1 Amostragem e quantização

A amostragem é o processo de discretização de uma imagem em suas coordenadas espaciais. Consiste em obter uma quantidade finita de pontos igualmente espaçados que representem uma função contínua  $f(x,y)$ . É possível classificar as imagens digitais, de acordo com o tipo de amostragem, em dois grandes grupos: imagens tipo vetorial e imagens tipo rastreo (VICTORIANO et al., 2015).

**Imagens vetoriais** são definidas a partir de cálculos matemáticos baseados em formas geométricas, o que confere a esse tipo de imagem uma alta resolução, não perdendo a definição em caso de redimensionamento. Devido a isso, necessitam de um intervalo de tempo maior para o processamento e por isso não são uma boa alternativa para sistemas de resposta online. São amplamente utilizadas em *softwares* como o *CorelDraw* e *Illustrator* e seus formatos mais comuns são o *.svg*, *.cdr*, *.ai* e *.eps*.

**Imagens de rastreo**, mais conhecidas como imagens *bitmap*, são verdadeiros mapas de *bits*: em cada coordenada do mapa podem ser encontrados dados de cor, brilho e intensidade do ponto analisado. Esses pontos são distribuídos em uma matriz  $m \times n$ , onde  $m$  e  $n$  são inteiros positivos e representam as coordenadas do ponto em um plano cartesiano. Cada elemento da matriz, alocado em uma posição  $(m,n)$  recebe o nome de *pixel*. Os formatos mais comuns desse tipo de imagem são *.bmt*, *.jpg*, *.gif* e *.tiff*, sendo amplamente utilizadas em aplicativos de visão computacional.

A quantização é a discretização em relação aos valores de brilho. Consiste em obter o valor de  $f(x,y)$  para cada *pixel* discretizado na amostragem e armazená-lo em sua posição correspondente dentro da matriz que representa a imagem (QUEIROZ & GOMES, 2001). O valor da função depende da codificação aplicada e as mais usuais são:

- (i) **preto e branco**, com 2 níveis de quantização. Cada *pixel* pode assumir valores 0, exibindo preto, ou 1, branco;
- (ii) **escala de cinza**, com 256 níveis de quantização. Cada *pixel* pode assumir valores entre 0 e 255, onde 0 representa o preto e 255, branco;

- (iii) **RBG**, com 256 níveis de quantização para cada um dos três canais de cores (vermelho, azul e verde), formando uma matriz tridimensional. Dessa forma, cada pixel de uma imagem colorida possui 3 valores, sendo (0, 0, 0) representando preto e (255, 255, 255), branco.

As etapas de amostragem e quantização para uma imagem em escala de cinza estão apresentadas na **Erro! Fonte de referência não encontrada.**

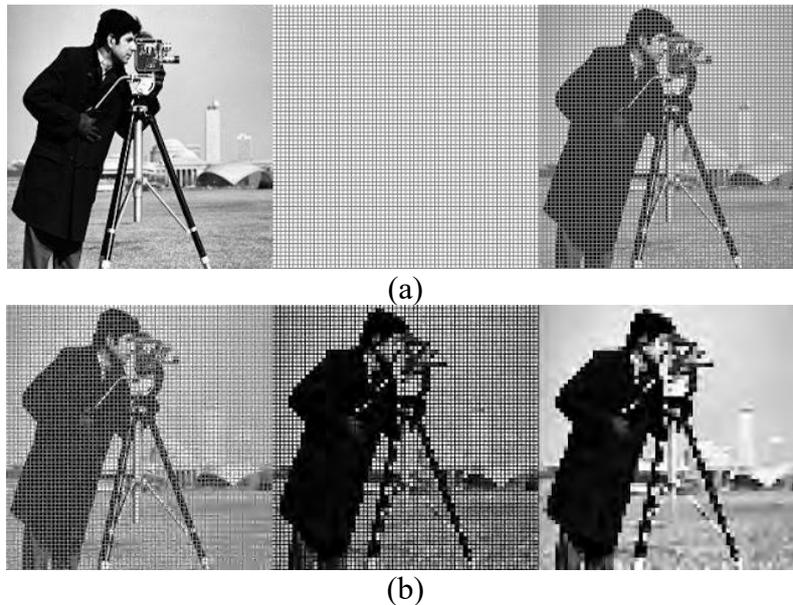


Figura 26. (a) Sequência de amostragem, (b) sequência de quantização.  
Fonte: QUEIROZ & GOMES, 2001.

### 5.1.2 Teorema da convolução

A **convolução** é um operador matemático que combina duas funções para gerar uma terceira, o que na engenharia pode ser visto como a descrição do comportamento de um sistema frente a uma perturbação. Pode ser contínua, muito utilizada em processamento de sinais, ou discreta, utilizada para operações de filtragem em processamento de imagens (SOVIERZOSKI, 2010).

Em se tratando de imagens *bitmap*, que são representadas por matrizes, a convolução gera uma terceira matriz a partir da multiplicação e soma entre elementos de duas outras matrizes. Um determinado ponto da matriz gerada é calculado pelo somatório dos produtos das duas matrizes nos pontos de mesma coordenada e de vizinhança do ponto em questão. Na **Erro! Fonte de referência não encontrada.**, a operação de convolução para o cálculo da coordenada em vermelho, que leva em consideração os pontos central, em vermelho e as vizinhanças, em verde (STOLFI, 2008).

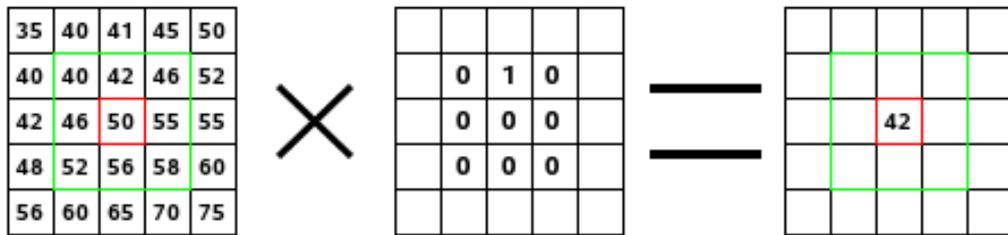


Figura 27. Representação de uma operação de convolução entre matrizes.  
 Fonte: STOLFI, 2008.

Outra forma de encontrar a matriz gerada, que corresponde à imagem filtrada, é fazendo a troca de domínio da função estudada. Segundo o Teorema da Convolução, a convolução entre duas funções no domínio do tempo ou espaço é equivalente a multiplicação dos seus espectros no domínio da frequência (**Erro! Fonte de referência não encontrada.**), operação muito utilizada junto a aplicação da Transformada de Fourier em filtragem digital de imagens (FONSECA NETO, 1999).

$$f(t) * g(t) \leftrightarrow F(f) . G(f) \quad \text{Equação 3}$$

## 5.2 Filtragem Digital

Define-se ruído de uma imagem toda a informação que, de alguma forma, prejudique o seu processamento. Podem ser classificados em: randômicos, quando estão presentes no domínio do espaço, ou periódicos, quando presentes no domínio da frequência (ESQUEF et al., 2003).

O objetivo da remoção de ruídos é obter uma imagem que possua o fator qualidade, que leva em consideração a fidelidade e a inteligibilidade. A fidelidade busca aproximar ao máximo a imagem processada da imagem original e a inteligibilidade se preocupa com a informação que pode ser extraída da imagem original. Este último fator é amplamente empregado em processamento de imagens com fins científicos (SCURI, 1999).

Há inúmeras possibilidades de ruídos decorrentes do processo de criação da imagem, como distorções oriundas de uma baixa amostragem/quantização ou iluminação precária, portanto, há também inúmeras possibilidades de operações de restauração e realce para corrigir cada um desses defeitos.

A seguir serão abordadas as técnicas aplicadas no desenvolvimento deste trabalho.

### 5.2.1 Manipulação de contraste

Quando uma imagem possui pouca variação entre os níveis de cinza é normal que a distinção entre os objetos em cena fique prejudicada, o que dificulta a análise das informações. Dessa forma, é necessário tratar cada *pixel* da imagem, independentemente de sua vizinhança e redistribuir os níveis de cinza de forma mais homogênea. Essa modificação pode ser realizada pela expansão de contraste ou pela equalização histográfica.

A **expansão de contraste** redistribui os tons de cinza de modo a elevar o contraste nas faixas de níveis possíveis, ou seja, alonga a faixa dos picos para as extremidades mantendo a

intensidade de cada um deles, como mostrado na **Erro! Fonte de referência não encontrada.** (GOMES, 2001).

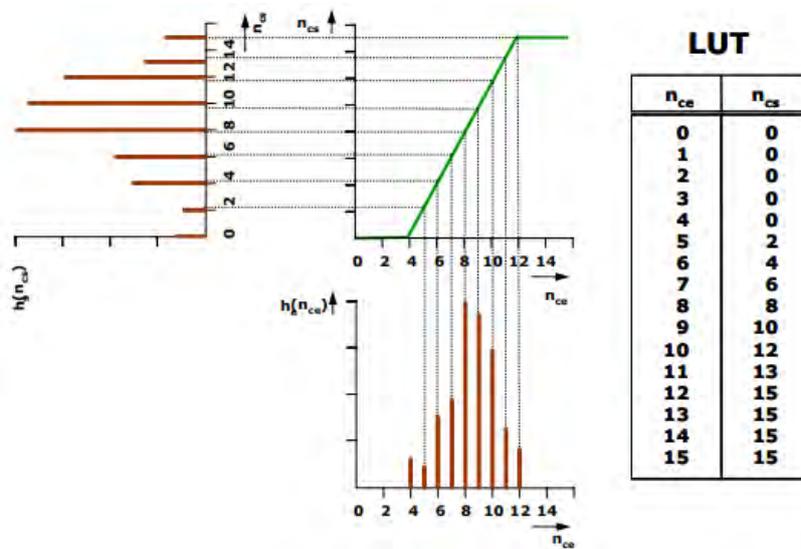


Figura 28. Expansão de contraste. Fonte: GOMES, 2001.

A expansão pode ocorrer de forma linear ou não linear, levando a resultados diferentes na imagem filtrada, como mostrado na **Erro! Fonte de referência não encontrada.**

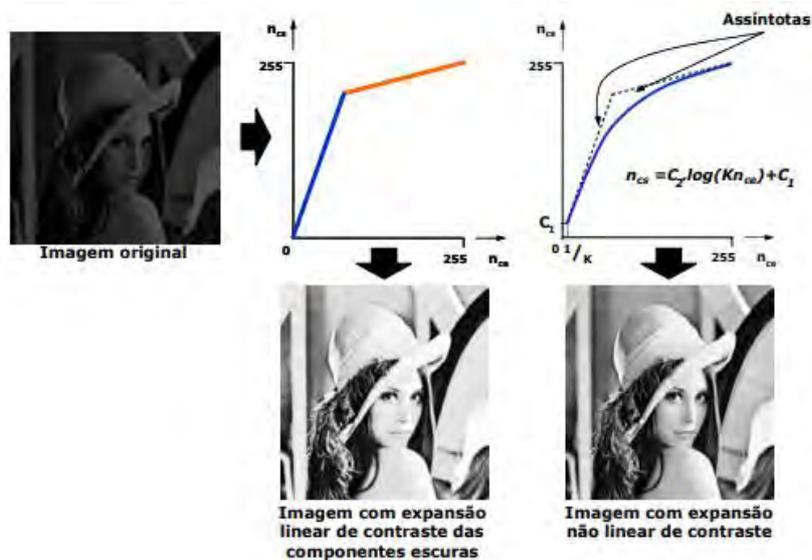


Figura 29. Expansão de contraste linear e não linear. Fonte: GOMES, 2001.

Diferentemente da expansão de contraste, a **equalização histográfica (Erro! Fonte de referência não encontrada.)** tem por objetivo redistribuir os tons de cinza de maneira uniforme, alterando não só os níveis, mas também a intensidade dos picos (GOMES, 2001). Dessa forma, tanto as áreas escuras quanto as áreas claras têm seu contraste realçado.

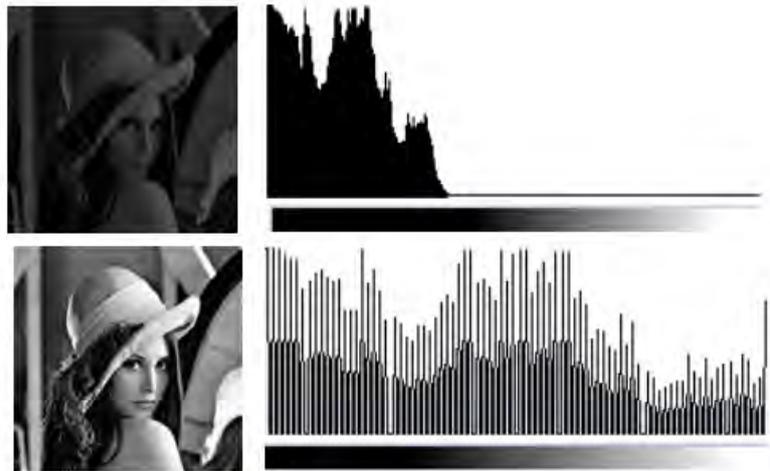


Figura 30. Equalização histogrâmica.  
Fonte: GOMES, 2001.

### 5.2.2 Filtros Lineares

São aplicados em operações lineares e podem ser analisados tanto no domínio espacial quanto no domínio da frequência (SANCHES et al., 2015). Nesse tipo de filtro a transformação é feita através da convolução entre a imagem e uma única máscara, definida de modo que somente uma vizinhança afete o *pixel* central. Neste caso, a matriz utilizada é a 3x3, ou as demais matrizes com as posições fora da primeira vizinhança assumindo o valor zero (COSTA, 1998).

Tem como finalidade a suavização da imagem sem alteração na média de luminância, podendo ser utilizados tanto para a retirada de pequenos detalhes quando para a conexão de pequenas discontinuidades em linhas da imagem (SANCHES et al., 2015).

São normalmente utilizados para separar componentes de frequência espacial presentes na imagem e nesse contexto, podem ser classificados em filtros passa baixa, passa alta e passa banda (COSTA, 1998).

**Filtros Passa Baixa:** removem componentes de alta frequência, ou seja, aqueles que provocam grande variação nos níveis de cinza. O fazem suavizando as regiões com essas variações bruscas e como consequência, podem provocar efeito de imagem embaçada. A operação matemática utilizada é a integração e o exemplo mais comum é o filtro de média.

**Filtros Passa Alta:** removem componentes de baixa frequência, com pouca variação nos níveis de cinza, realizando a intensificação de bordas e de detalhes finos da imagem. Esse tipo de filtro realiza o realce direcional, com máscaras de gradiente direcional e o realce não direcional, com filtros Laplacianos, por exemplo e a operação matemática utilizada é a derivação.

**Filtros Passa Banda:** também chamados filtros passa-faixa, permitem a seleção e remoção, de faixas específicas de frequência. São geralmente usados para o realce de bordas em imagens ruidosas. Como exemplo, o filtro linear de Sobel.

### 5.2.3 Filtros não-lineares

São aplicados em operações não-lineares, podendo utilizar ou não as máscaras de convolução. Utilizam processos que se baseiam em operadores de gradiente e filtros morfológicos.

**Operadores de gradiente** são filtros do tipo passa alta que realizam convoluções entre um par de máscaras, que medem o gradiente em cada ponto e a imagem. A vantagem em sua utilização é que, devido a operação com mais de uma máscara, tem-se informações mais completas a respeito das bordas, o que permite análises mais apuradas. Os filtros não lineares mais utilizados são o de Roberts, Prewitt e Sobel.

**Filtros morfológicos**, ao contrário, não realizam convoluções, mas se baseiam em um procedimento semelhante que provém da morfologia matemática: uso de operadores booleanos e elementos estruturantes. Esses últimos têm sua forma dependente da conectividade adotada e são utilizados no lugar das máscaras, indicando com 1 os *pixels* que serão considerados na operação e com 0, os *pixels* ignorados.

O objetivo é extrair informações dos objetos em relação a sua forma e estrutura e como exemplo de operadores, têm-se a erosão e a dilatação. A erosão trata de um processo de expansão dos elementos escuros que se pareçam com o elemento estruturante utilizado e permite separar objetos que se tocam; a dilatação, faz o mesmo para os elementos claros, permitindo o preenchimento de pontos no interior do objeto.

Dois processos comuns são o de abertura e fechamento (**Erro! Fonte de referência não encontrada.**). A abertura trata de uma erosão seguida de uma dilatação e tem como efeito a suavização de contornos, suprimindo pequenos pontos claros isolados na imagem. O fechamento trata de uma dilatação seguida de uma erosão, realizando o mesmo efeito que a abertura, só que para os pontos escuros (COSTA, 1998).

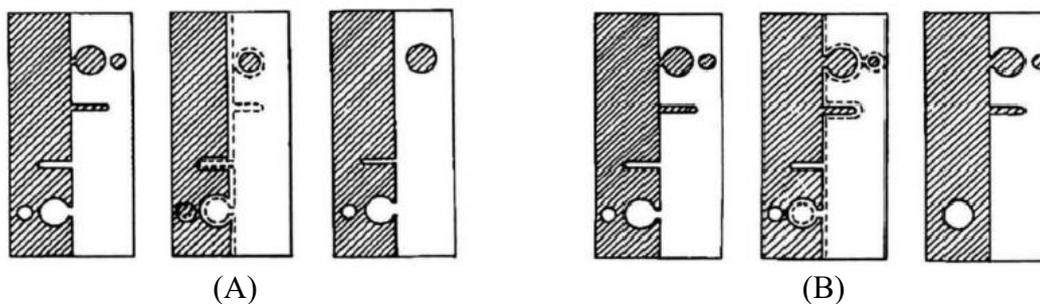


Figura 31. (A) Fechamento; (B) Abertura.  
Fonte: Adaptado de COSTA, 1998.

Os filtros citados acima são os mais comumente usados em processamento digital e tem suas características de tamanho e intensidades pré-definidas. Apesar disso, é possível que para alguns casos nenhum deles seja capaz de fornecer resultados satisfatórios, o que não é de fato um problema. Máscaras podem ser criadas manualmente completamente adaptáveis ao objetivo que se deseja alcançar com a filtragem digital.

## 5.3 Técnicas de Segmentação

### 5.3.1 Limiarização de Otsu

A operação de limiarização, conhecida como *thresholding*, se fundamenta na análise de similaridade de tons de cinza para realizar a segmentação da imagem. Pode utilizar limiar único ou limiares múltiplos, dependendo da quantização que se deseja alcançar.

O processo de limiar único segmenta a imagem em duas regiões, a chamada binarização. Para limiares múltiplos, a segmentação ocorre com a transformação da imagem em outra com 2 ou mais níveis de cinza, a depender de quantos limiares forem definidos. A maior dificuldade desse processo é escolher o limiar T mais adequado para a correta segmentação das regiões (GOMES, 2001).

O método de Otsu, proposto por Nobuyuki Otsu em 1975, é um dos algoritmos mais utilizados para a binarização e realiza a busca por um *threshold* T que separe de forma satisfatória os elementos dos planos de fundo e de frente em dois *clusters*, a que são atribuídas as cores preto e branco, respectivamente, na imagem binarizada fornecida na saída do algoritmo. A proposta é realizar uma varredura no histograma de níveis de cinza em busca do T que melhor represente a separação dos grupos, o que é feito a partir da minimização da função de variância **intraclasse**  $\sigma_{W-intra}^2$  (**Erro! Fonte de referência não encontrada.**).

$$\sigma_{W-intra}^2 = (W_b \times \sigma_b^2) + (W_f \times \sigma_f^2) \quad \text{Equação 4}$$

Os valores  $W_b$  e  $W_f$  são chamados de pesos e representam a probabilidade de um *pixel* pertencer ao plano de fundo e de frente, respectivamente. Os valores  $\sigma_b^2$  e  $\sigma_f^2$  são as variâncias dentro de cada um dos *clusters* separadamente. Uma outra opção é a maximização da variância **interclasse**  $\sigma_{W-inter}^2$  (**Erro! Fonte de referência não encontrada.**), que utiliza, além dos pesos, as médias  $\mu_b$  e  $\mu_f$  relacionada a cada grupo individualmente, o que leva ao mesmo resultado anterior com menor custo do ponto de vista computacional (TOROK, 2015). A resposta do método para maximização da variância interclasse pode ser vista na **Erro! Fonte de referência não encontrada.**

$$\sigma_{W-inter}^2 = W_b W_f (\mu_b - \mu_f)^2 \quad \text{Equação 5}$$

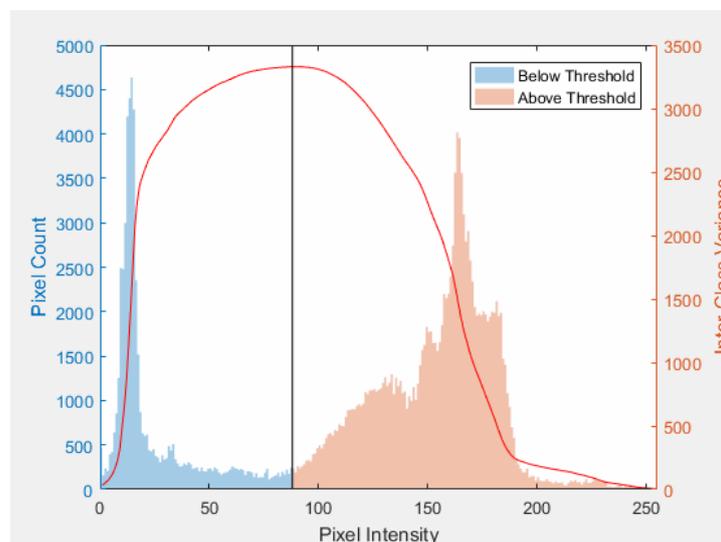


Figura 32. Método de Otsu – Variância Interclasse.  
 Fonte: CC-BY-AS.

**DESCRIÇÃO DO MÉTODO:**

Inicialmente é feito o cálculo do histograma da imagem em tons de cinza. Em seguida, o primeiro valor de T é escolhido como zero, primeiro nível de cinza e a varredura na imagem é iniciada.

Nesse passo é feita a comparação entre a intensidade P de cada *pixel* com T. Caso P seja menor que T, será atribuído ao *pixel* o valor zero e caso P seja maior que T, o valor 1. Feito isso, é hora de calcular os pesos e variâncias inerentes à cada classe e depois, calcular a variância intraclasse.

O processo é repetido até que todos os valores de níveis de cinza sejam testados e o T ideal será aquele que minimize a variância intraclasse. A descrição esquemática pode ser melhor entendida com a **Erro! Fonte de referência não encontrada.** (TOROK, 2015).

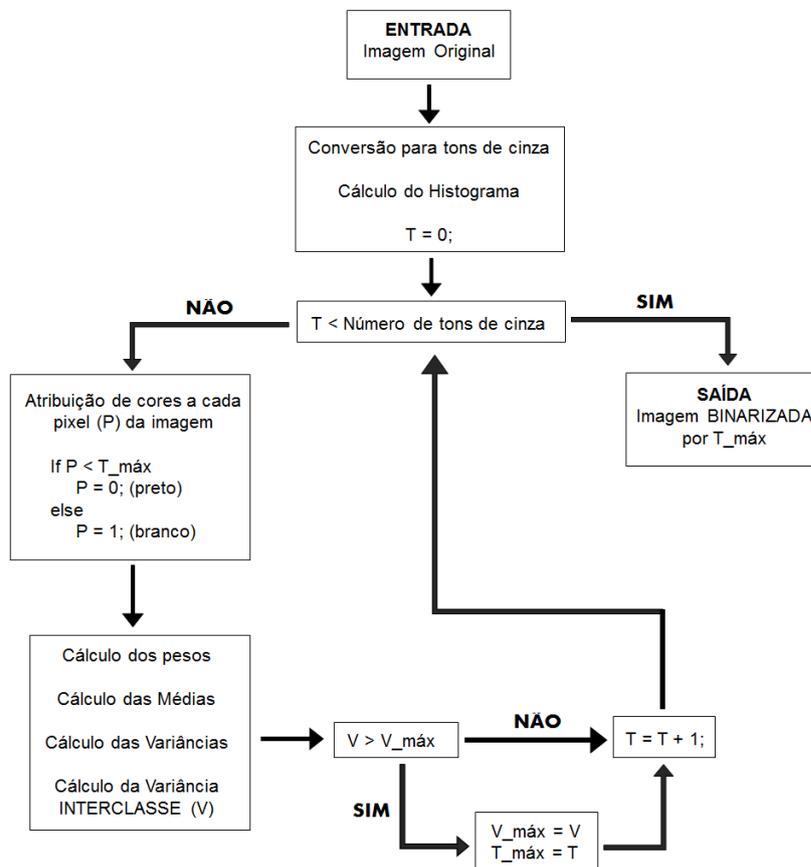


Figura 33. Fluxograma do algoritmo do Método de Otsu. Fonte: O autor.

**5.3.2 Algoritmo *k-means***

As técnicas de agrupamento, também chamadas de *clustering*, são métodos de aprendizado não-supervisionado baseados em similaridades encontradas no conjunto de dados. Seu objetivo principal é dividi-los em grupos, chamados *clusters*, de forma que os dados pertencentes a um mesmo *cluster* sejam semelhantes entre si e diferentes dos dados de outros clusters. O algoritmo *k-means* é um dos exemplos de clustering mais utilizados, por sua fácil

aplicação e tem como objetivo dividir o conjunto de dados em ‘k’ *clusters* utilizando algum critério de similaridade, ambos previamente definidos pelo operador (MALHEIROS, 2017).

Um exemplo em que um mesmo conjunto de dados é dividido em 2 *clusters* utilizando três critérios de similaridade diferentes pode ser visto na Figura 34 **Erro! Fonte de referência não encontrada.**

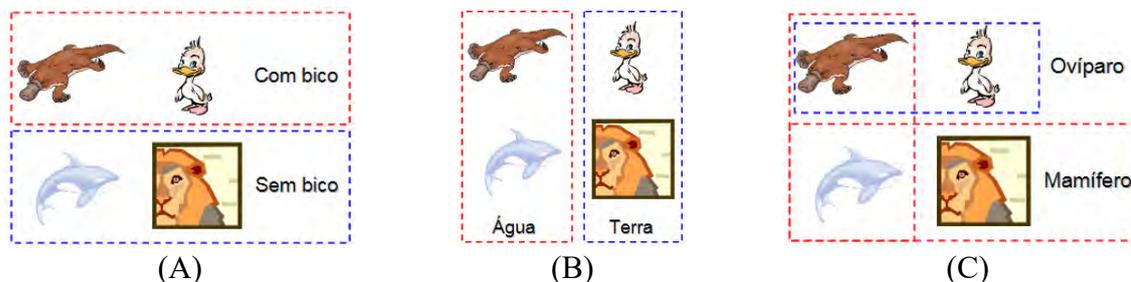


Figura 34. Agrupamento de um mesmo conjunto de dados segundo critérios diferentes.

Fonte: BARANAUSKAS, 2020.

O exemplo anterior é simples e bastante intuitivo, levando em consideração a capacidade visual de um observador humano. Entretanto, esses mesmos dados são apresentados a uma máquina na forma de uma matriz tridimensional que contém somente números, o que torna o processo de classificação muito mais complexo.

Avaliando agora somente entradas numéricas, suponha uma dispersão de pontos num plano cartesiano, em que o operador deseja que haja a divisão em três *clusters* utilizando o método *k-means*. Como os dados são desconhecidos, o algoritmo escolhe aleatoriamente os pontos que servirão como referência para a busca de similaridades e estes são chamados de centróides. Em geral, o que define que um ponto faça parte de um determinado *cluster* é a distância entre ele e o centróide de referência, de forma os pontos de um mesmo *cluster* estejam o mais próximos possível.

A medida em que pontos novos são acrescentados ao problema, a forma geométrica do *cluster* muda, principalmente se os pontos estiverem em áreas de menor densidade de dados. Dessa forma, a cada atribuição, é necessário que os centróides sejam recalculados e ajustados. O problema ocorre quando o ponto adicionado não pertence a nenhum dos grupos existentes, ou seja, quando uma nova classe deveria ser criada para representá-lo. Estes são chamados *outliers* e levam a distorção da posição dos centróides, afetando de forma negativa a segmentação. A atribuição às classes é mostrada na **Erro! Fonte de referência não encontrada.**, onde cada *cluster* é representado por uma cor diferente; os centróides, por triângulos; e os pontos atribuídos, por círculos (MALHEIROS, 2017; TIAN et al., 2019).

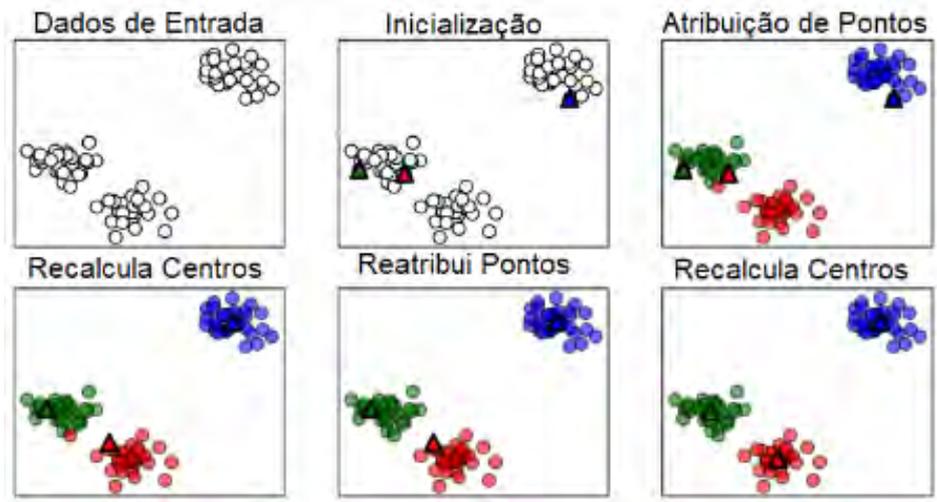


Figura 35. Algoritmo *k-means*.  
 Fonte: Adaptado de MALHEIROS, 2017.

Outro problema deste método está relacionado à escolha randômica dos centróides iniciais, suporte para a construção dos *clusters*. Quando os grupos não são muito bem definidos, ou seja, quando a diferença entre a distância do ponto para dois centróides diferentes for pequena, é possível encontrar respostas diferentes ao executar o mesmo algoritmo, nas mesmas condições (MALHEIROS, 2017).

O método *k-means* pode ser aplicado a diversos tipos de conjuntos de dados, entretanto, como o objetivo deste trabalho envolve o processamento de imagens, o conjunto de dados fornecido será uma matriz numérica tridimensional, que representa uma imagem colorida.

### **DESCRIÇÃO DO MÉTODO:**

Primeiramente a imagem é convertida para o espaço LAB de cores, que apresenta melhor desempenho nesse tipo de classificação comparado ao RGB. Depois, *k pixels* aleatórios são definidos pelo operador como centroide dos *clusters*. No caso de imagens, cada ponto possui três valores, cada um associado a cada canal de cores.

Um *pixel* é selecionado e a distância euclidiana entre ele e cada centróide é calculada, de forma que ele pertença ao *cluster* que apresentar a menor distância. Para o caso da aplicação deste algoritmo no processo de segmentação, cada *cluster* será representado por uma matriz bidimensional, do tamanho da imagem original, inicializada com zeros. A cada *pixel* analisado na imagem original, modifica-se o valor, para a mesma coordenada da matriz a que foi atribuído, para 1. Este processo se repete para todos os *pixels* da imagem.

Feito isso, os centróides são recalculados e os pontos são novamente atribuídos. O processo iterativo ocorre até que, por pelo menos três vezes consecutivas, a diferença entre os valores de todos os centróides na iteração atual e anterior seja menor que o valor determinado como tolerância. Como resposta final, obtém-se uma máscara binarizada, ou seja, uma matriz tridimensional em que as linhas e colunas representam as coordenadas dos *pixels* em relação a imagem original e cada camada representa um *cluster*.

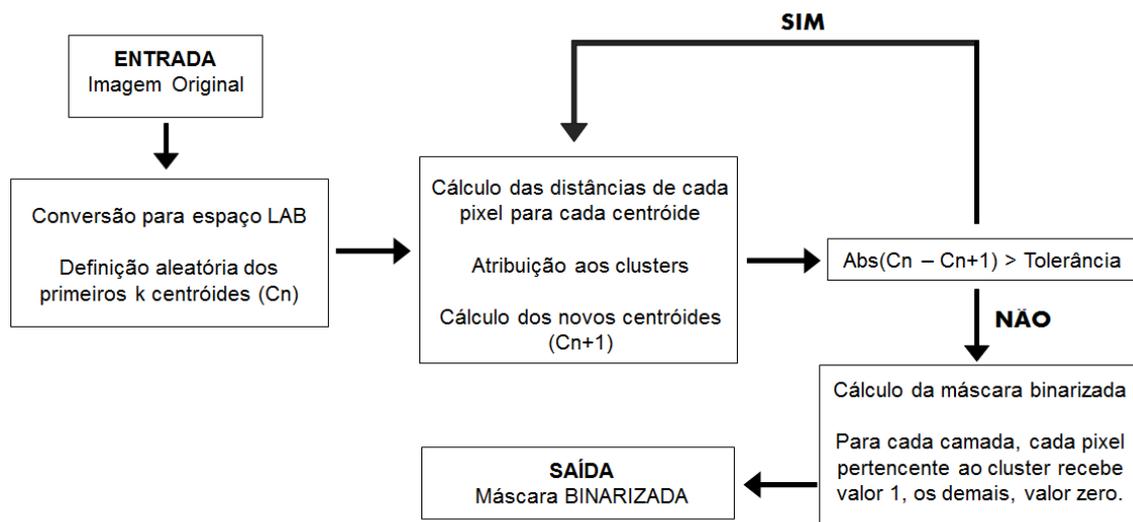


Figura 36. Fluxograma do algoritmo do Método de *k-means*.  
Fonte: O autor.

### 5.3.3 Transformada Discreta Bidimensional de Fourier

A Transformada de Fourier é uma ferramenta matemática utilizada para transformar o domínio de funções, variando entre tempo/espaço e frequência. Sua aplicabilidade é ampla, já que muitas vezes é mais interessante analisar a frequência com que um determinado sinal se apresenta, ou o desvio em relação a um valor de referência, do que saber a posição ou o tempo em que ele ocorreu (NAJARIAN & SPLINTER, 2006).

A Transformada Contínua de Fourier é aplicada a funções contínuas, como por exemplo sinais analógicos, entretanto, os sistemas digitais largamente utilizados atualmente requerem a discretização das funções para redução de domínio e maior eficiência. Nesse contexto se insere a Transformada Discreta de Fourier (DFT), aplicada a sinais discretizados, muitas vezes obtidos por amostragem periódica dos sinais contínuos. A DFT é obtida a partir da discretização da Série de Fourier que representa o processo estudado e seus coeficientes são melhor estimados quanto menor for o intervalo de amostragem (PUPIN, 2011).

Como abordado no primeiro tópico desse capítulo, a imagem digital é formada pela discretização da cena real, que para esse estudo, é representada por imagens *bitmaps*. Como resposta, obtém-se uma matriz, em que cada ponto do “mapa de *bits*” representa uma intensidade luminosa. Dessa forma, pode-se dizer que uma imagem é uma função bidimensional, que recebe como argumentos as coordenadas de um ponto e devolve a intensidade luminosa, independente de quantos canais de cores possua.

A DFT também pode ser aplicada a funções bidimensionais (DFT-2D) e as equações 6 e 7 mostram o par da DFT direta em inversa para esse caso. A variável  $f(x, y)$  representa a imagem no domínio do tempo/espaço;  $N$  e  $M$  representam, respectivamente, o número de linhas e colunas da matriz da imagem;  $x$  e  $y$  representam as coordenadas de cada *pixel* e podem variar de 0 até, respectivamente,  $N - 1$  e  $M - 1$ ;  $w_x$  e  $w_y$  representam as frequências, encontradas pela relação  $\Delta w_x = \frac{1}{N \cdot \Delta x}$  e  $\Delta w_y = \frac{1}{M \cdot \Delta y}$ ; e  $F(w_x, w_y)$  representa a imagem no domínio da frequência. A exponencial mostrada nas equações pode ser associada a funções

trigonométricas a partir da identidade de Euler:  $e^{-2i\pi z} = \cos(2\pi z) + i.\text{sen}(2\pi z)$  (OLIVEIRA FILHO, 1999).

$$\mathfrak{F}[f(x, y)] = \frac{1}{\sqrt{N \cdot M}} \cdot \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot e^{-2i\pi \left( \frac{w_x \cdot x}{N} + \frac{w_y \cdot y}{M} \right)} \quad \text{Equação 6}$$

$$\mathfrak{F}^{-1}[F(w_x, w_y)] = \frac{1}{\sqrt{N \cdot M}} \cdot \sum_{w_x=0}^{N-1} \sum_{w_y=0}^{M-1} F(w_x, w_y) \cdot e^{2i\pi \left( \frac{w_x \cdot x}{N} + \frac{w_y \cdot y}{M} \right)} \quad \text{Equação 7}$$

Segundo Fourier, qualquer sinal pode ser representado como uma soma de funções seno e para imagens, estas são representadas pela variação de brilho. As informações contidas numa imagem senóide podem ser expressas pelas variáveis frequência espacial, magnitude e fase (NAJARIAN & SPLINTER, 2006).

A frequência espacial representa a frequência com que a intensidade luminosa no ponto é representada, variando de zero até a “frequência de Nyquist”, valor máximo de intensidade relacionado com a resolução de aquisição das imagens. Dessa forma, a imagem mantém seu tamanho ao ser convertida de um domínio a outro, sem perda de informação. A magnitude corresponde à diferença entre os picos mais claros e escuros da imagem, o chamado contraste e informa o quanto de certo componente da frequência espacial pode ser encontrado na imagem. A fase representa a forma como o seno é transladado e informa onde cada componente de frequência está localizado (NAJARIAN & SPLINTER, 2006).

Tratando-se de funções bidimensionais, as variáveis capazes de expressar imagens são o Espectro de Fourier (**Erro! Fonte de referência não encontrada.**), relacionado à magnitude, o ângulo de fase (**Erro! Fonte de referência não encontrada.**) e o Espectro da Potência (**Erro! Fonte de referência não encontrada.**). Vale mencionar que a Transformada de Fourier tem como resposta uma função complexa, portanto possui componentes reais e imaginários.

$$|F(w_x, w_y)| = \left\{ \Re[F(w_x, w_y)]^2 + \Im[F(w_x, w_y)]^2 \right\}^{1/2} \quad \text{Equação 8}$$

$$\phi(w_x, w_y) = \arctan \left( \frac{\Im[F(w_x, w_y)]}{\Re[F(w_x, w_y)]} \right) \quad \text{Equação 9}$$

$$|F(w_x, w_y)|^2 = \Re[F(w_x, w_y)]^2 + \Im[F(w_x, w_y)]^2 \quad \text{Equação 10}$$

A DFT-2D é separável, o que faz com que o custo computacional de sua aplicação possa ser reduzido. Dessa forma, convém utilizar as chamadas Transformadas Rápidas de Fourier (FFT's) para analisar cada uma das partes da equação como uma série unidimensional (GONÇALVES, 2004).

A filtragem digital é um processo fundamental em processamento digital e uma das formas de realizar a filtragem é dada no domínio de Fourier utilizando o Teorema da Convolução (TC). Como visto, o TC defende que a convolução entre duas funções no domínio

tempo/espaco equivale a multiplicação ponto a ponto das mesmas funções no domínio da frequência, ou seja, equivale ao produto dos dois espectros de Fourier.

Com base nessa informação é possível aplicar qualquer tipo de filtro a uma imagem senóide, desde que a ele também seja aplicada a respectiva Transformada de Fourier. Neste trabalho, esta técnica tem como finalidade a segmentação, detecção de objetos em uma imagem, então a segunda função senóide será representada por um *kernel* com a finalidade de detecção de contornos.

### DESCRIPÇÃO DO MÉTODO:

Primeiramente, a imagem é convertida para níveis de cinza e os filtros de atuação vertical e horizontal utilizados para a detecção de bordas são definidos. Como a imagem fornecida ao algoritmo pode não possuir o mesmo tamanho nas duas dimensões, é preciso encontrar o maior tamanho para que este seja o tamanho do espectro de potência gerado.

Na sequência, é aplicada a transformada rápida de Fourier na imagem e nos dois filtros e a operação de filtragem é efetuada pela multiplicação ponto a ponto da imagem com cada um dos filtros. Como resposta, são obtidas duas imagens filtradas, uma como resultado da atuação vertical e outra como resultado da atuação horizontal.

Por fim, é aplicada a transformada inversa nas imagens, que retornam ao domínio espacial. As imagens são combinadas para formar a imagem de saída com as bordas detectadas e posteriormente binarizadas para detecção dos objetos e cálculo das características.

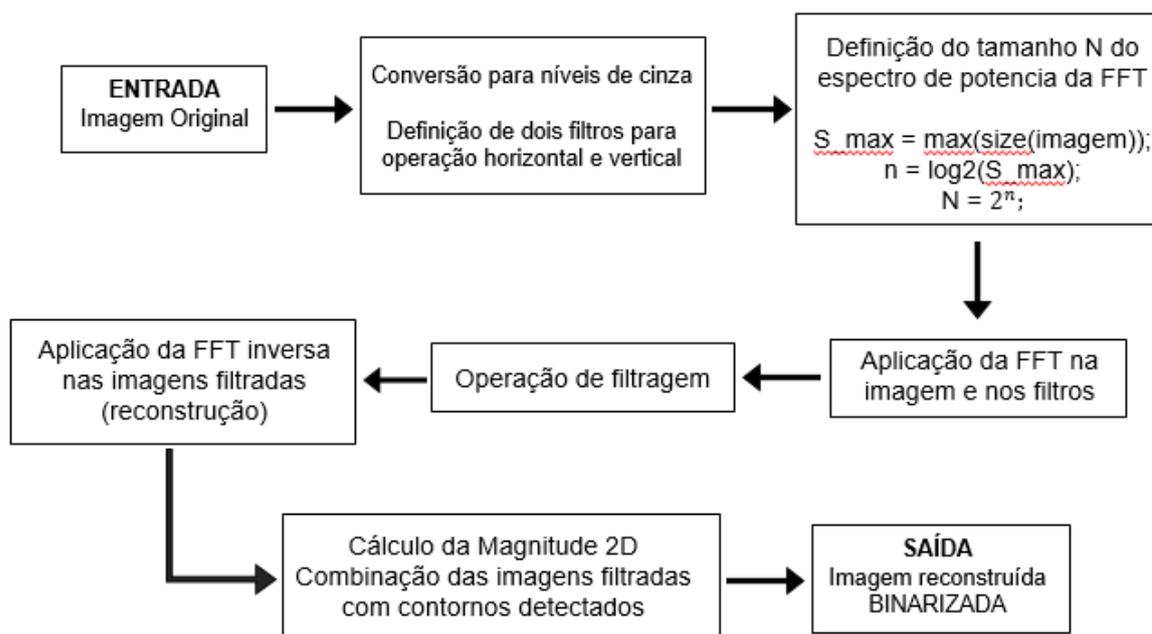


Figura 37. Fluxograma do algoritmo do Método da Transformada de Fourier.

Fonte: O autor.

### 5.3.4 Transformada Wavelets

Como visto anteriormente, a Transformada de Fourier (TF) é uma ferramenta muito útil para a análise e processamento de sinais no domínio da frequência, uma vez que muitas vezes as informações mais importantes que não podem ser observadas no domínio do tempo. Apesar

da grande aplicabilidade, a TF não indica em qual instante de tempo cada um dos espectros encontrados ocorre, não apresentando bom desempenho especialmente em caso de comportamento não estacionário, caracterizado por mudanças de tendências, quebras estruturais, que podem ocorrer a qualquer momento do evento analisado. (GUTIERREZ, 2002).

Como alternativa, foi desenvolvida a Transformada de Fourier de Tempo Curto (STFT), uma versão da TF que utiliza janelas no tempo para decompor o sinal em tempo e frequência. Entretanto, o método utiliza uma única janela temporal para avaliar todas as frequências, o que limita os resultados quanto a valores muito altos e muito baixos, que precisam de maior flexibilidade para que o conteúdo local seja detectado (CESAR, 2018; CASTAÑÓN, 2003). Além disso, a escolha da janela deve ser feita de forma a encontrar um equilíbrio entre o número de elementos analisados, já que as resoluções nos domínios da frequência e tempo são, respectivamente, diretamente e inversamente proporcionais ao tamanho da janela (SILVA, 2017).

Para solucionar esse problema foi introduzido o primeiro conceito de *wavelets*, que utiliza versões escalonadas e dilatadas de uma mesma função, a *wavelet* mãe, para construir uma família de funções que será utilizada como janela. Quando um sinal é de baixa frequência, o tempo de observação é maior e de forma análoga, tempos muito curtos de observação são necessários para visualização de altas frequências. Dessa forma, as Transformadas *Wavelets* (TW's) estudam cada componente de frequência com a escala adequada, fornecendo resultados mais precisos (CESAR, 2018).

A TW pode ser, então, definida como uma ferramenta matemática utilizada para a decomposição hierárquica de funções, sejam elas unidimensionais, como sinais elétricos, ou bidimensionais, como imagens. Uma propriedade das TW's é que, diferentemente das TF's, suas funções têm duração limitada, o que é chamado de suporte compacto. Isso significa que ela possui valores diferentes de zero no domínio em que atuam e igual a zero nos demais valores, o que faz com que sua utilização para o caso de análise de imagens seja particularmente interessante no procedimento de detecção de bordas (CASTAÑÓN, 2003).

A análise multirresolução (AMR) tem como objetivo representar uma função em diferentes níveis de resolução, em diferentes escalas, com a vantagem de transitar entre os níveis com perdas bem pequenas, muitas vezes já associadas ao trabalho com funções discretas. Para o caso de processamento de imagens, pode ser vista como um algoritmo de pirâmides, em que são feitas aproximações sucessivas na imagem de forma a reduzir exponencialmente seu tamanho (GABOARDI, 2009). É possível, então, representar a imagem inteira com uma quantidade muito reduzida de valores, que podem ser aproveitados para a criação do vetor de características que representa a imagem (CASTAÑÓN, 2003).

O algoritmo piramidal da AMR funciona a partir da convolução da imagem de entrada com dois filtros, passa alta e passa baixa, reamostrando a função numa escala correspondente à metade da anterior. Como saída, são obtidas quatro matrizes, que correspondem à imagem original suavizada e aos coeficientes de detalhes extraídos para as direções horizontal, vertical e diagonal (GABOARDI, 2009; SILVA, 2017). Ao aplicar filtros passa-baixas obtém-se os coeficientes de aproximação, que dão origem à imagem suavizada do próximo nível. Analogamente, ao aplicar filtros passa-altas, obtém-se os coeficientes de detalhes. A decomposição de um nível utilizando TW's está representada na **Erro! Fonte de referência não encontrada.**

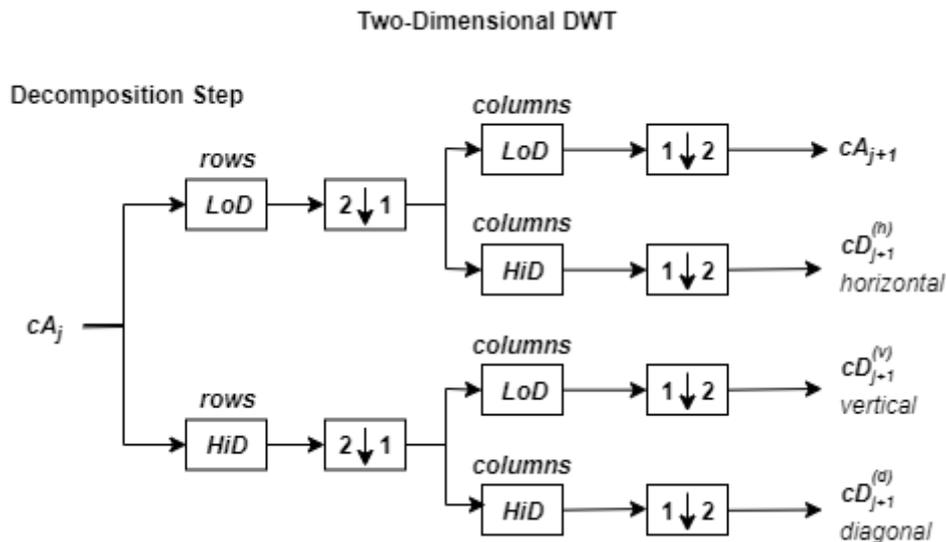


Figura 38. Representação da decomposição com TW's para um nível.  
Fonte: Mathworks.

Na figura acima,  $cA_j$  pode representar a imagem original, para o caso do primeiro nível de decomposição, ou os coeficientes de aproximação do nível anterior, para os demais níveis. A imagem suavizada é primeiramente submetida a duas operações de convolução na direção das linhas, cada uma com um dos filtros (passa altas e passa baixas) originados da família de wavelets escolhida para análise. A resposta passa por uma operação de downsampling, responsável por reduzir à metade a escala da imagem. Na sequência, outras quatro operações de convolução são realizadas com os mesmos filtro na direção das colunas, originando as quatro matrizes de saída do nível. A matriz com os coeficientes de aproximação é formada com a aplicação de filtro passa baixas nas duas direções e é a imagem de entrada do próximo nível. As demais matrizes contêm os coeficientes de detalhes, que serão posteriormente utilizamos para a reconstrução da imagem original.

### **DESCRIÇÃO DO MÉTODO:**

O procedimento adotado realiza primeiro a equalização histogrâmica da imagem em cores, o que realça as características das partículas em escoamento. Na sequência, a imagem é convertida para níveis de cinza e fornecida para a função `wavedec2` do Matlab©, responsável pela decomposição por wavelets descrita acima. Além da imagem também precisam ser fornecidos dois parâmetros: o número de níveis que se deseja decompor e a família de wavelets que será utilizada na decomposição, que neste caso, é a Haar.

Como resposta são obtidas duas variáveis: o vetor de decomposição, que contém todos os coeficientes obtidos; e a matriz de escrituração, que contém as dimensões desses coeficientes, que será utilizada na reconstrução da imagem. Em relação ao vetor de decomposição, vale destacar que as matrizes obtidas para coeficientes de aproximação, detalhes na horizontal, detalhes na vertical e detalhes na diagonal são transformadas em vetores e organizadas nesta ordem para cada nível. O vetor de decomposição, então, será a concatenação dos vetores obtidos a cada nível.

Para a detecção das bordas é feita uma operação de filtragem no vetor de decomposição, em que os valores dos coeficientes são alterados a partir de um threshold, definido de acordo com o tamanho desse vetor. Isso significa que os dados do vetor de decomposição são ordenados por ordem crescente e o limiar é definido como o valor correspondente ao elemento que se encontra a uma porcentagem do tamanho do vetor.

O vetor resultante da operação de filtragem é então fornecido à função `waverec2` do Matlab©, juntamente à matriz de escrituração e ao parâmetro que define a família de wavelets, o mesmo utilizado na decomposição, para a reconstrução da imagem com bordas detectadas.

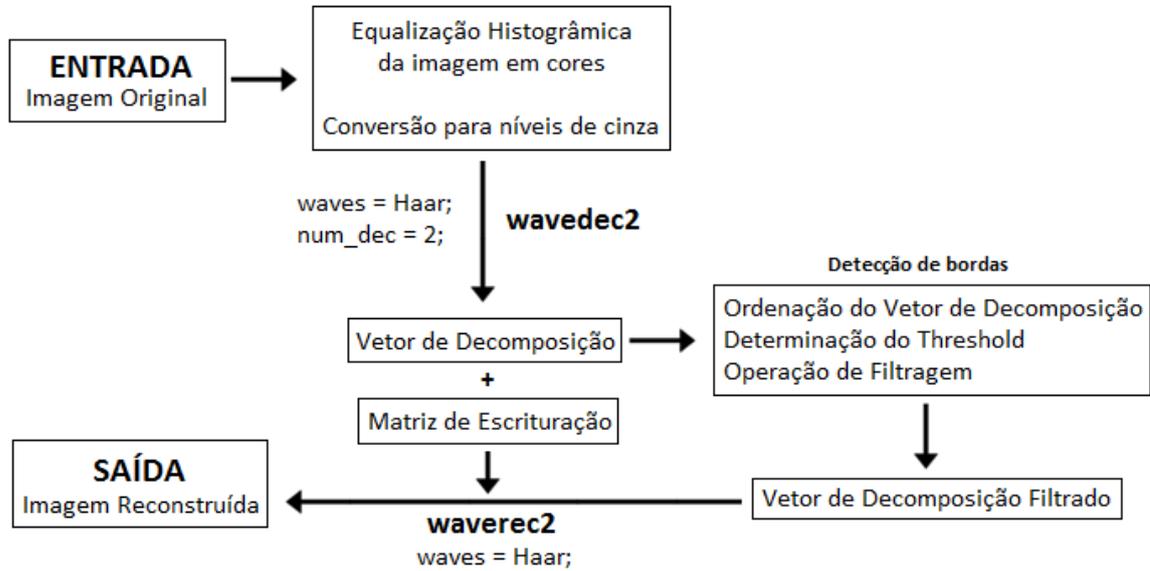


Figura 39. Fluxograma do algoritmo do Método da Transformada de Wavelets.

Fonte: O autor.

## 5.4 Visão Computacional – Detectores de Objetos

A Visão Computacional é um segmento da Inteligência Artificial que utiliza como fundamento o sistema biológico da visão para realizar uma série de tarefas relacionadas à detecção de objetos e extração de informações de imagens digitais. Para isso, é necessário que a máquina seja capaz de processar e contextualizar padrões de formas, textura e intensidades luminosas, de maneira a diferenciar objetos de interesse do restante da cena.

Nas últimas décadas foram desenvolvidos algoritmos com a capacidade não somente de identificar objetos em uma imagem, mas de buscá-los em outras imagens a partir da detecção de pontos-chave, também chamados pontos de interesse. A grande vantagem dessa abordagem é o menor custo computacional, uma vez que um ou alguns pontos são necessários para caracterizar o objeto como um todo (JESUS, 2019). O impacto é mais positivo ainda em problemas onde as imagens possuem dimensões muito altas e com alto nível de correlação entre *pixels* (MONTANARI, 2015; JESUS, 2019).

Um mesmo objeto pode ser detectado em diversas imagens porque é formado por uma região de *pixels* que não varia para mesmas condições de aquisição, o que é chamado de invariância local. Isso significa que, dentro dos limites do objeto, um determinado *pixel* central possui sempre a mesma relação com suas vizinhanças, ou seja, possui sempre os mesmos descritores locais. Caso as condições de aquisição variem, o que significa ter imagens distorcidas, borradas ou com iluminação variável, a tarefa de correspondência fica mais difícil (SILVA et al., 2013). Dessa forma, detectar todos os *pixels* de um objeto ou um pequeno grupo deles leva ao mesmo resultado: o objeto está presente em cena.

O objetivo deste estudo é monitorar o escoamento de sólidos diversos através de vídeos, que podem ser divididos em imagens, os chamados *frames*. A tarefa dos detectores é, então, identificar o mesmo sólido em dois *frames* sequenciais, o que é feito comparando-se os descritores locais de todos os pontos de interesse detectados nos dois *frames*. A comparação pode ser feita por distâncias Euclidiana, Hamming ou qualquer outra (SILVA et al, 2013). O funcionamento desses detectores é o mesmo: inicialmente é feita uma varredura na imagem em busca dos pontos de interesse e quando encontrados, a informação sobre posição e escala de suas vizinhanças é utilizada no cálculo dos descritores locais (OLIVEIRA, 2018).

### **DESCRIÇÃO DO MÉTODO:**

O primeiro *frame* do vídeo fornecido ao aplicativo é submetido a uma etapa de pré-processamento, que envolve transformações projetivas e geométricas e o recorte da região que será avaliada. Na sequência, é executado um dos algoritmos de detecção de pontos chave, que recebe como entrada o recorte de análise e retorna um objeto com as características dos pontos detectados. O próximo *frame* é submetido ao mesmo processo e tem seus pontos de interesse, com as respectivas características, armazenadas em um segundo objeto. Por fim, as informações contidas nos dois objetos são cruzadas e quando as características de um ponto no objeto 1 são equivalentes com algum ponto no objeto 2, sinaliza-se que este objeto está presente nos dois *frames*. Como uma das informações é a coordenada do ponto detectado, é possível monitorar o deslocamento de objetos de um *frame* para o outro. Ao realizar esse procedimento para todos os *frames*, monitora-se o escoamento ao longo do vídeo. O fluxograma de detecção de pontos de interesse para um detector qualquer está representado na **Erro! Fonte de referência não encontrada.**

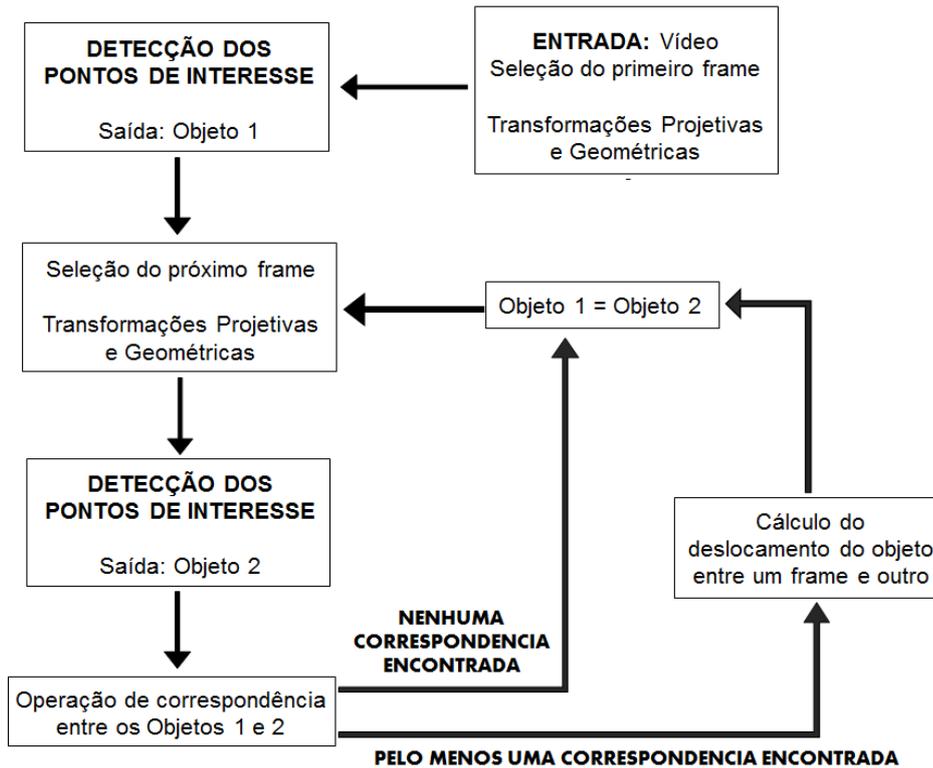


Figura 40. Fluxograma do algoritmo de detecção de pontos de interesse.  
Fonte: O autor.

Como mencionado, existem diversos algoritmos capazes de detectar pontos-chave e cada um o faz utilizando métodos diferentes. A seguir serão mostrados os métodos dos três detectores utilizados neste trabalho.

### 5.4.1 Harris Corner Detector

O detector de Harris é um dos detectores mais aplicados atualmente por sua invariância à rotação, escala, iluminação e ruídos da imagem. Tem como base a autocorrelação entre um *pixel* central e sua vizinhança próxima, avaliada para diferentes direções e utiliza expansão de Taylor nas aproximações. Isso é feito utilizando a imagem em níveis de cinza e a posição do *pixel* que está sendo avaliado. Um ponto é considerado ponto de interesse quando é representado por uma quina, ou seja, precisa possuir valor alto de autocorrelação com suas vizinhanças para as direções x e y (SRIVIDHYA & PRAKASH, 2017; JESUS, 2020).

Caso o módulo do valor retornado da autocorrelação seja baixo, o gradiente de intensidade entre o *pixel* central e as vizinhanças é pequeno, ou seja, a variação das intensidades é baixa, o que é característico de pontos de fundo e de interior de objetos (**Erro! Fonte de referência não encontrada.A**). Caso o módulo de valor retornado seja alto, o gradiente de intensidades também será, o que é característico de pontos de borda em geral. Gradientes reais negativos representam variações somente em uma das direções e caracterizam bordas regulares de objetos (**Erro! Fonte de referência não encontrada.B**), enquanto gradientes positivos representam variações nas duas direções, característicos de quinas (**Erro! Fonte de referência não encontrada.C**) (JESUS, 2019).

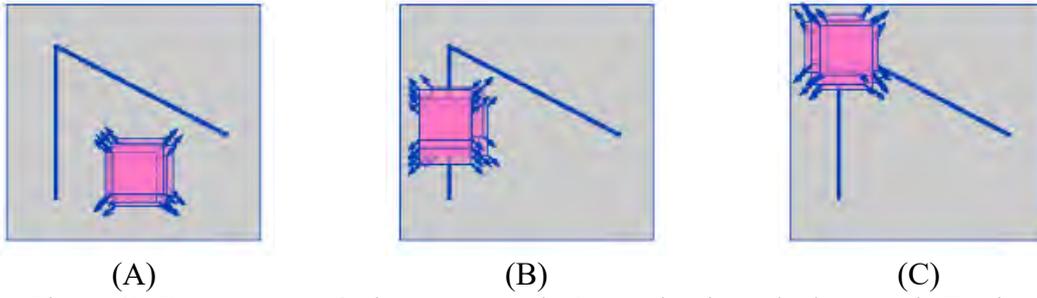


Figura 41. Respostas possíveis para a correlação no algoritmo do detector de Harris.

(A) Pontos de região homogênea, superfície plana, fundo ou interior de objetos.

(B) Pontos de borda. (C) Pontos de quina.

Fonte: Adaptado de JESUS, 2019.

Agora, matematicamente, considere um recorte de tamanho  $(u, v)$  da imagem para verificação de pontos de quina utilizando o detector de Harris. Este recorte pode ser expressado por  $I(u, v)$ , onde  $I$  representa a imagem. Ao percorrer a área de análise nas duas direções, tem-se que cada ponto pode ser representado por  $I(x + u, y + v)$ . Fazendo a aproximação por expansão de Taylor, é possível obter a seguinte expressão da **Erro! Fonte de referência não encontrada.**, onde  $I_x$  e  $I_y$  são as derivadas parciais da imagem (SRIVIDHYA & PRAKASH, 2017).

$$I(x + u, y + v) \approx I(u, v) + [x \times I_x(u, v)] + [y \times I_y(u, v)] \quad \text{Equação 11}$$

Ao calcular a soma ponderada das diferenças quadráticas (**Erro! Fonte de referência não encontrada.**) da aproximação obtida na **Erro! Fonte de referência não encontrada.** obtém-se a matriz  $A$ , chamada matriz de Harris, representada pelo tensor estrutural mostrado na **Erro! Fonte de referência não encontrada.** O termo  $w(u, v)$  é a ponderação aplicada a  $I(u, v)$ , realizada por uma operação de convolução. A escolha mais comum para este termo é uma gaussiana, que retorna uma resposta circularmente simétrica, chamada isotrópica (SRIVIDHYA & PRAKASH, 2017; JESUS, 2019).

$$S(x, y) \approx (x, y) \times A \times \begin{pmatrix} x \\ y \end{pmatrix} \quad \text{Equação 12}$$

$$A = \sum_u \sum_v w(u, v) \otimes \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \quad \text{Equação 13}$$

As variações nas intensidades dos *pixels* são representadas pelos autovalores da matriz  $A$ , que identificam as regiões de canto quando  $M$  (**Erro! Fonte de referência não encontrada.**) retorna um valor alto e positivo. Caso o valor de  $M$  seja negativo, o ponto corresponde a uma borda e caso seja baixo, corresponde a uma região homogênea. A variável  $k$  é um parâmetro de sensibilidade do método, ajustável a cada problema (JESUS, 2019; ZACARKIM, 2017).

$$M = \det(A) - k \times \text{tr}^2(A) \quad \text{Equação 14}$$

$$\text{Onde } \det(A) = \lambda_1 \times \lambda_2 = I_x^2 \times I_y^2 - (I_x I_y)^2 \quad e \quad \text{tr} = \lambda_1 + \lambda_2 = I_x^2 + I_y^2$$

### 5.4.2 Speed Up Robust Features – SURF

Assim como o detector de Harris, o detector SURF também possui grande aplicação devido a sua invariância a escala e rotação, entretanto, apesar de ser considerado um método rápido e robusto, sua resposta pode ser insuficiente quando variações de cor e iluminação entre as imagens analisadas passam a ser significativas (ALMEIDA, 2018<sup>2</sup>).

Os pontos de interesse deste método são determinados de forma similar ao detector de Harris: a partir da análise dos autovalores da matriz característica do método, que neste caso é uma aproximação simples da matriz Hessiana da imagem integral (ALMEIDA, 2018<sup>2</sup>; JESUS, 2020). O grande diferencial deste método é utilizar o conceito de imagem integral ponderada por filtros caixa, responsáveis pela notável redução no tempo de processamento (ZACARKIM, 2017). A **Erro! Fonte de referência não encontrada.** mostra a matriz Hessiana  $H(x, y)$ , onde as variáveis  $L$  representam a resposta da operação de convolução entre a imagem e os filtros Gaussianos de segunda ordem  $W$ .

$$H(x, y) = W \otimes \begin{bmatrix} I_{xx} & I_{xy} \\ I_{xy} & I_{yy} \end{bmatrix} = \begin{bmatrix} L_{xx} & L_{xy} \\ L_{xy} & L_{yy} \end{bmatrix} \quad \text{Equação 15}$$

Uma imagem integral é construída a partir do somatório das intensidades de todos os *pixels* desde a origem, ponto superior esquerdo demarcado pela letra O na **Erro! Fonte de referência não encontrada.**, até a coordenada do *pixel* que se deseja avaliar como ponto de interesse (MARTINS, 2014).

Na **Erro! Fonte de referência não encontrada.**, (A) representa a matriz de intensidades da imagem de entrada, com o recorte de análise sombreado em azul; (B) corresponde à imagem integral calculada para toda a imagem original, onde as intensidades mostradas para cada *pixel* correspondem ao somatório das intensidades da origem até o *pixel* avaliado. Observe que o mesmo recorte demarcado em (A) também foi delimitado em (B), mas agora com valores cumulativos.

Dessa forma, conhecendo-se as coordenadas do recorte de análise é possível determinar de forma rápida a imagem integral do trecho que se deseja analisar. Além disso, componentes de alta frequência são preservados e não é necessária nenhuma operação de interpolação para criação de novas imagens em caso de modificação de escala (MARTINS, 2014).

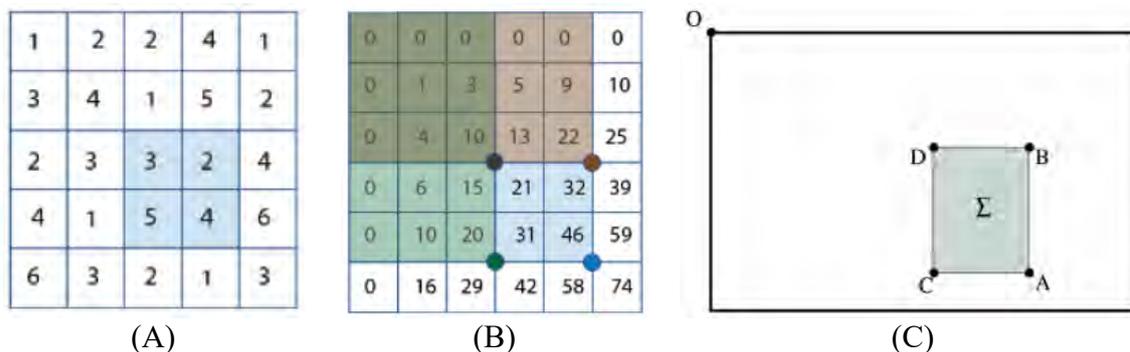


Figura 42. (A) Matriz que representa a imagem original; (B) Matriz que representa a imagem integral; (C) Ilustração do sistema de coordenadas. Fonte: Adaptado de BRAZ JUNIOR, 2009.

Assim como no método de Harris, o termo de ponderação representa operações de convolução entre a imagem e um filtro Gaussiano, que neste caso é de segunda ordem. O

método SURF propõe uma aproximação desses filtros gaussianos, os chamados filtros caixa (JESUS, 2019). Na **Erro! Fonte de referência não encontrada.** é mostrado, na linha superior, três filtros baseados em funções Gaussianas de segunda ordem, respectivamente nas direções horizontal, vertical e diagonal. A linha inferior da **Erro! Fonte de referência não encontrada.** ilustra as aproximações para obtenção dos filtros caixa correspondentes a cada um dos filtros Gaussianos apresentados.

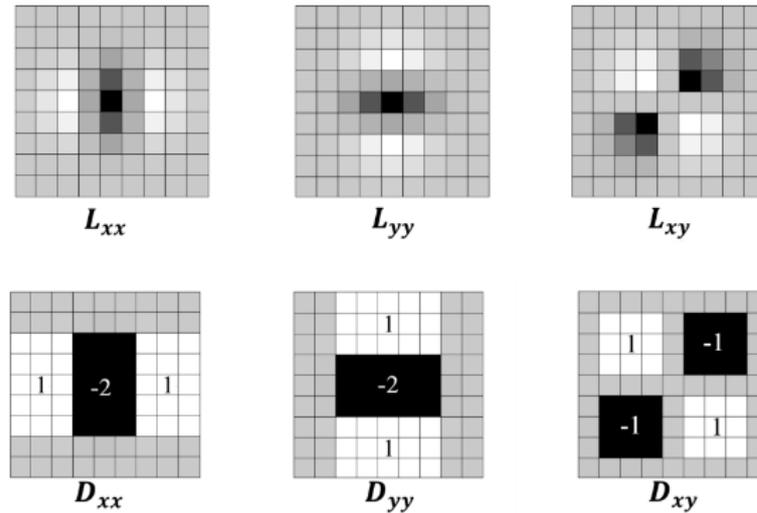
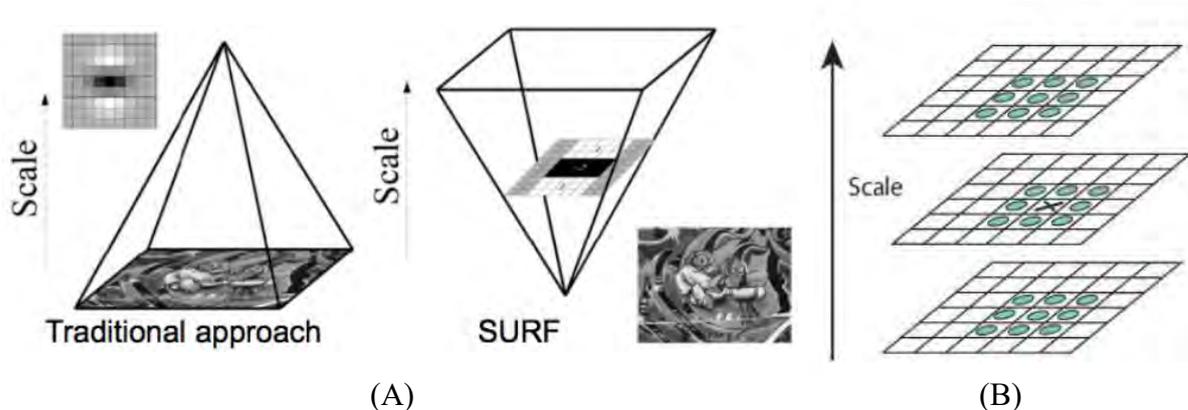


Figura 43. Linha superior: filtros baseados em funções Gaussianas de segunda ordem. Linha inferior: aproximações dos filtros da linha superior para filtros caixa.

Fonte: Adaptado de JESUS, 2019.

Devido a utilização de imagens integrais, o método SURF propõe, ainda, a aplicação de filtros de convoluções de vários tamanhos diferentes, formando um espaço de escala em que a imagem é analisada (**Erro! Fonte de referência não encontrada.**<sup>a</sup>) (NOVAIS, 2016; JESUS, 2019). Os pontos de interesse são determinados por processo de supressão não máxima, avaliando-se todas as imagens criadas no espaço de escala. Este processo compara o valor de um *pixel* central com seus 27 vizinhos (**Erro! Fonte de referência não encontrada.**<sup>B</sup>) e elimina pixels que não se apresentem como máximos locais (VALE & POZ, 2002).



(A) Ilustração do (A) espaço de escala e da (B) supressão de não máximos do método SURF.

Fonte: Adaptado de BRAZ JUNIOR, 2009.

### 5.4.3 Maximally Stable Extremal Region – MSER

O detector MSER foi apresentado por Matas et al. (2002) com a proposta de identificar objetos a partir de regiões de interesse e não mais pontos, que pudessem ser correspondidos ao analisar duas imagens do mesmo objeto em perspectivas diferentes. Essas regiões são formadas por *pixels* conectados que apresentam intensidades mais altas ou mais baixas que os *pixels* das extremidades, as chamadas *extremal region* (PEREIRA, 2018).

A definição das regiões extremas é feita avaliando-se as imagens resultantes do processo de limiarizações consecutivas, de forma semelhante ao método *watershed* (JURASZEK, 2014). A imagem binarizada com um determinado *threshold* tem como resposta regiões extremas de mínimo, em preto e de máximo, em branco. Ao realizar binarizações consecutivas com limiares crescentes, é possível perceber que os pequenos pontos pretos inicialmente detectados aumentam de tamanho e alguns se unem, formando objetos maiores (JURASZEK, 2014). As regiões extremas, então, são representadas, em cada binarização, por esses conjuntos de *pixels* que se unem para formar um objeto.

O objetivo desse algoritmo é encontrar regiões extremas maximamente estáveis, ou seja, regiões que praticamente não variam de tamanho para um determinado número de *thresholds*. A diferença, comparado ao algoritmo *watershed*, é que neste último o objetivo é encontrar os limiares em que regiões menores se conectam para formar regiões maiores (JURASZEK, 2014). **A Erro! Fonte de referência não encontrada.** a seguir ilustra em (A) a imagem original, de (B) a (G) os passos de binarização sequencial com limiar crescente e em (H) a imagem em níveis de cinza com as regiões extremas detectadas (PEREIRA, 2018).

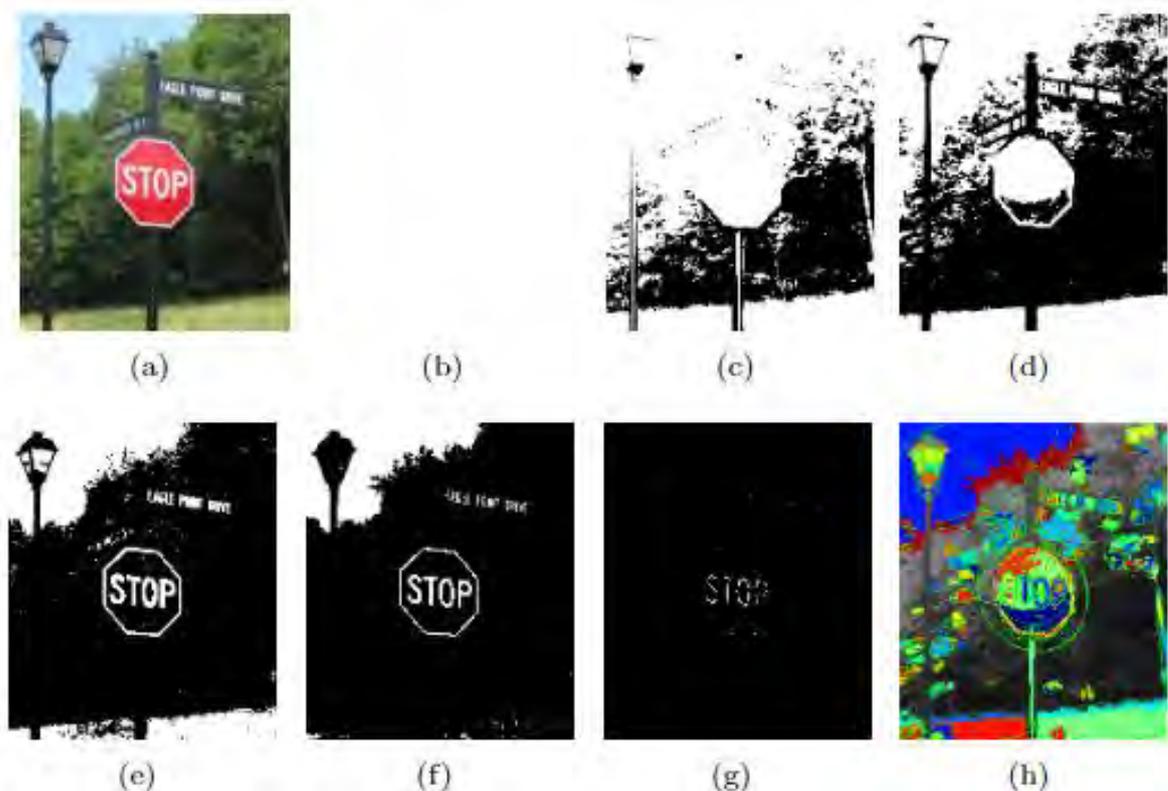


Figura 45. Detecção de regiões extremas utilizando o algoritmo MSER. (A) Imagem original; (B)  $T = 0$ ; (C)  $T = 50$ ; (D)  $T = 100$ ; (E)  $T = 150$ ; (F)  $T = 200$ ; (G)  $T = 250$ ; (H) = Regiões extremas detectadas.

Fonte: PEREIRA, 2018.

Matematicamente, cada região  $i$  tem seu tamanho determinado pela função  $q(T)$  como o número de *pixels* conectados em cada um dos limiares  $T$  definidos e a resposta para regiões maximamente estáveis é encontrada com a minimização da função de estabilidade  $d(q_i)$ , descrita pela **Erro! Fonte de referência não encontrada.** (SILVA et al., 2013).

$$d(q_i) = \frac{q_i(T + 1) - q_i(T - 1)}{q_i(T)} \quad \text{Equação 16}$$

Diferente dos outros métodos apresentados, o algoritmo define um objeto e retorna como propriedade de posição o equivalente ao centróide da região detectada. Com isso, a cada binarização os centróides são calculados e as regiões demarcadas por elipses. A etapa final do processo consiste na avaliação da estabilidade desses centróides, que quando alcançada, funde as elipses equivalentes de forma a demarcar a região extrema (MSER - MathWorks).

A grande vantagem no uso deste detector é sua invariância a pequenas distorções, rotação, translação e escalonamento, alcançada pelo método de detecção de regiões. Além disso, tem baixo custo computacional e é multi-escalar, apresentando boa resposta na detecção de regiões grandes e pequenas. Em contrapartida, sua eficiência é limitada para imagens muito borradas, com variações significativas de iluminação natural, ou com contraste muito baixo, em que há dificuldade de detecção dos limites das regiões (PEREIRA, 2018).

## 5.5 Características Texturais

Uma das capacidades inerentes ao ser humano é a diferenciação visual de padrões a partir da interpretação de sua textura. Dessa forma, a análise textural, surgiu como alternativa para a análise de imagens com menor custo computacional, já que pode fornecer informações a respeito da distribuição espacial, rugosidade, luminosidade e arranjo estrutural da cena analisada (OLIVEIRA et al., 2014).

Abordagens simples para a descrição de texturas, com os chamados descritores de primeira ordem, utilizam intensidades de *pixels* fornecidas pelo histograma de cores, o que leva a uma resposta um pouco limitada. De maneira a aproveitar melhor as informações fornecidas foram propostos os descritores de segunda ordem, que avaliam as intensidades dos *pixels* e posição relativa dos que apresentam intensidades iguais ou similares. (SILVA, 2007; OLIVEIRA et al., 2014). Haralick et al. (1973) propuseram em seu trabalho um método capaz de armazenar essas informações em forma de matriz, as chamadas matrizes de co-ocorrência (GLCM's), para depois avaliá-las estatisticamente.

### 5.5.1 Matrizes de co-ocorrência

Uma matriz de co-ocorrência representa a distribuição de probabilidade da dependência espacial das intensidades dos *pixels* (COSTA, 2010). Em outras palavras, é uma matriz de frequências relativas, obrigatoriamente quadrada, que indica o número de vezes que uma determinada transição de níveis de cinza ocorre. Essa ferramenta é utilizada para mapear quantas diferentes combinações de intensidades podem ocorrer em uma imagem, considerando para a análise dois *pixels* por vez (NASCIMENTO, 2003).

O primeiro *pixel* é o de referência e o segundo o *pixel*, chamado vizinho, tem localização descrita pela função de deslocamento  $\delta(d, \theta)$ , onde  $d$  representa a distância em *pixels* entre os dois *pixels* avaliados e  $\theta$  representa o ângulo formado entre o *pixel* de referência e seu vizinho.

Em geral, a escolha para  $d$  é de um *pixel* e os ângulos podem ser descritos nas direções horizontal, vertical e diagonal (SOUTO JUNIOR, 2010).

Na **Erro! Fonte de referência não encontrada.** é mostrado o *pixel* de referência, marcado no centro por um círculo preenchido e os *pixels* vizinhos numerados de acordo com os ângulos, que podem assumir os valores 0, 45, 90 e 135. Para construir uma GLCM é necessário escolher apenas um valor para distância e um valor para o ângulo. Dessa forma, para cada distância podem ser calculadas quatro GLCM's, aumentando o número de descritores estatísticos finais capazes de representar a imagem.

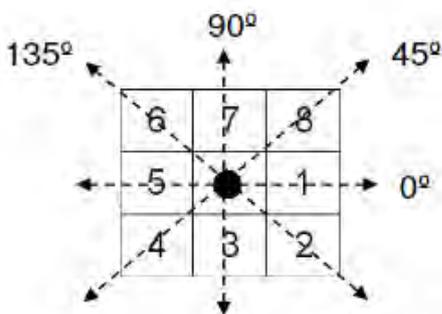


Figura 46. Direções possíveis para o cálculo da matriz de co-ocorrência.  
Fonte: SOUTO JUNIOR, 2010

Na **Erro! Fonte de referência não encontrada.** tem-se, à esquerda, a representação das intensidades de níveis de cinza para uma imagem qualquer, variando em 8 níveis, e à direita, construção de sua GLCM. Para esse exemplo, são definidos  $d = 1$  *pixel* e  $\theta = 0^\circ$ . O número de linhas e colunas da GLCM representam o número de níveis de cinza que a imagem possui, que neste caso varia de 0 até 7. As linhas representam o valor de intensidade atribuído ao *pixel* de referência e as colunas, ao *pixel* vizinho. A matriz é inicializada com zeros e conforme a imagem é percorrida, as atualizações são feitas.

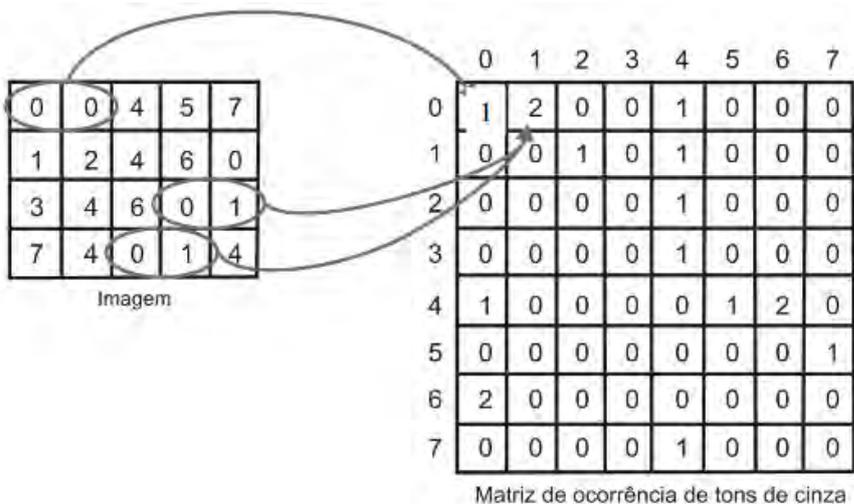


Figura 47. Mecanismo para construção de uma GLMC.  
Fonte: CONCI, 2015

O *pixel* de posição (0,0) na imagem possui intensidade igual a zero e tomando-o como referência, tem-se que seu vizinho também possui intensidade zero. Dessa forma, será atualizada a posição (0,0) da GLCM com um incremento, já que ambos, referência e vizinho, apresentam valor zero. Há somente uma ocorrência dessas intensidades com essa configuração espacial, então o valor na GLCM final, nesta posição, é igual a 1.

Observando agora os outros dois exemplos circundados, tem-se que o *pixel* de referência tem intensidade zero e o vizinho, intensidade 1. Dessa forma, a posição (0,1) da GLCM será atualizada com o número 2, por haver duas ocorrências para esta configuração.

Com as intensidades e frequências mapeadas, é possível aplicar cálculos estatísticos capazes de caracterizar as texturas.

### 5.5.2 Descritores de Haralick

Haralick et al. (1973) propuseram em seu trabalho o cálculo de até 16 descritores estatísticos capazes de caracterizar texturas variadas. O método inicialmente propõe o cálculo da matriz de co-ocorrência da imagem e a normalização de seus valores, ou seja, a representação da GLCM como uma matriz de probabilidades de ocorrência. Feito isso, os descritores são calculados.

Os itens a seguir mostram cada um desses descritores, o que representam e de que forma são calculados, onde  $P(i, j)$  representa a probabilidade de ocorrência de um *pixel*  $i$  ao lado de um *pixel*  $j$ . Essas informações foram adaptadas das seguintes referências: COSTA, 2010; SOUTO JUNIOR, 2010; CONCI, 2015; e SOUZA, 2017.

- Energia ou Uniformidade ou Segundo Momento Angular

Avalia a periodicidade da imagem, o seu ordenamento. Em geral, texturas artificiais apresentam alta periodicidade, ou seja, estruturas que regularmente se repetem, fazendo com que a distribuição de níveis de cinza seja uniforme. Dessa forma, valores altos na GLCM levam a valores de energia próximos de um.

$$Energia = \sum_i \sum_j [P(i, j)]^2 \quad \text{Equação 17}$$

- Contraste

Avalia a variação dos níveis de intensidade local para pares de *pixels*, buscando mudanças bruscas nos níveis de cinza da imagem, ou seja, buscando altas frequências de co-ocorrência entre valores altos e baixos de intensidade. Baixos valores de contraste são retornados quando os elementos da GLCM estão concentrados na diagonal principal, ou seja, ainda que todos os valores de intensidade sejam encontrados na imagem e transição entre eles não é representada por mudanças bruscas, como em detecção de bordas, mas sim variações suaves de intensidade.

$$Contraste = \sum_i \sum_j (i - j)^2 P(i, j) \quad \text{Equação 18}$$

- Correlação

Avalia o quão correlacionado linearmente um *pixel* está com seu vizinho. Quanto mais áreas com intensidades de níveis de cinza similares, maior o valor retornado por este descritor.

$$\text{Correlação} = \frac{1}{(\sigma_i \sigma_j)} \sum_i \sum_j (ij)P(i, j) - \mu_i \mu_j \quad \text{Equação 19}$$

- Variância

Medida de dispersão que mostra como varia a diferença entre o *pixel* de referência e a média de seus vizinhos dentro de uma janela de análise. Quanto maior a homogeneidade da imagem, mais próximo de zero deve ser o valor retornado por este descritor.

$$\text{Variância} = \sum_i \sum_j (i - \mu)^2 P(i, j) \quad \text{Equação 20}$$

- Homogeneidade

Mede a autocorrelação espacial da distribuição total das intensidades de níveis de cinza. Quanto mais homogênea for a imagem, maior a concentração de ocorrências na diagonal principal da GLCM e assim, maior a homogeneidade.

$$\text{Homogeneidade} = \sum_i \sum_j \frac{P(i, j)}{1 + (i - j)^2} \quad \text{Equação 21}$$

- Entropia

Avalia as ocorrências encontradas na imagem, de forma que quanto menos uniforme, característico de texturas naturais, maior é o valor encontrado para este descritor.

$$\text{Entropia} = - \sum_i \sum_j P(i, j) \log[P(i, j)] \quad \text{Equação 22}$$

- Momento de diferenças de ordem k

Avalia a distorção da imagem. Quanto mais concentradas na diagonal principal estiverem as ocorrências, menor o valor deste descritor.

$$\text{MD} - k = \sum_i \sum_j (i - j)^k P(i, j) \quad \text{Equação 23}$$

- Momento inverso de diferenças de ordem k

Avalia o inverso do momento de diferenças de ordem k. Quando menos elementos na diagonal principal, maior o valor deste descritor.

$$\text{IMD} - k = \sum_i \sum_j \frac{P(i, j)}{(i - j)^k} \quad \text{Equação 24}$$

- Variância Inversa

Representa o inverso do contraste. Para esse descritor, os valores de intensidade dos *pixels* devem ser obrigatoriamente diferentes.

$$\text{Variância inversa} = \sum_i \sum_j \frac{P(i, j)}{(i - j)^2} \text{ para } i \neq j \quad \text{Equação 25}$$

- Probabilidade Máxima

É o descritor mais simples proposto por Haralick et al. (1973) e calcula o valor máximo da GLCM normalizada. Pode indicar a direção mais importante da textura analisada.

$$\text{Probabilidade Máxima} = \max_{i,j}[P(i,j)] \quad \text{Equação 26}$$

Além desses, outros descritos podem ser calculados: a variância da soma e média da soma, que representam a média e a variância totais da GLCM; a entropia da soma e entropia da diferença, que representam medidas de aleatoriedade total considerando a soma e diferença de *pixels* de referência e vizinhos; e a variância da diferença, que indica uma medida de disparidade na imagem.

## 5.6 Aprendizado de Máquina

O aprendizado de máquina, mais conhecido pelo termo *machine learning*, é a área da ciência que estuda a capacidade das máquinas de adquirirem conhecimento e resolver diversos problemas a partir dele. Para isso, esta técnica usa informações disponíveis para entender o contexto em que o problema se exhibe e criar as soluções, podendo ter sua interação com o ambiente ajustada a medida com que mais informação é obtida.

Atualmente essa tecnologia está fortemente presente na vida das pessoas, em pesquisas *web*, filtragem de conteúdo em redes sociais e recomendações de produtos de acordo com buscas recentes de usuários, seja em computadores ou *smartphones*. Esses sistemas identificam objetos em imagens e padrões de escrita e fazem correspondências com notícias e propagandas (LECUN et al., 2015).

Segundo Marques (2018), o escopo de qualquer sistema de *machine learning* está fundamentado em quatro pilares: banco de dados, modelo, função custo e algoritmo de otimização. Em resumo, um banco de dados é fornecido à máquina, que utiliza o modelo para fornecer respostas. O desempenho do modelo é medido pela função custo, que utiliza o algoritmo de otimização para sua minimização e ajuste de parâmetros.

O banco de dados (*datastore* - DS) é representado por um conjunto de informações que possuam alguma relação entre si e que estejam relacionadas ao problema proposto. Pode ser formado por planilhas, imagens, sons, todo tipo de dados. Dependendo da complexidade, é necessário que o DS receba pré-tratamento para alcançar uma solução satisfatória (MARQUES, 2018).

Um modelo é a ferramenta estatística utilizada para geração de respostas, que ajusta seus parâmetros na etapa de treinamento de forma a encontrar a melhor hipótese de representação dos dados. Uma estratégia muito eficiente para determinação do modelo adequado é a divisão dos problemas segundo o objetivo de sua resolução.

Os três tipos mais encontrados em *machine learning* são regressão, classificação e clusterização. Problemas de regressão tem como objetivo a predição de variáveis; de clusterização, o agrupamento de dados não rotulados; e de classificação, a identificação da categoria a qual uma determinada entrada desconhecida pertence (MARQUES, 2018). Os métodos mais populares são a regressão linear e logística para regressão; *k-means* para clusterização; e árvores de decisão e *Support Vectors Machine* para classificação. Redes Neurais Artificiais podem ser usadas em todos os modelos.

A função custo é a responsável pela avaliação da acurácia do algoritmo escolhido e utiliza parâmetros de proximidade para comparar valores estimados e valores reais. Muitos modelos utilizam a função erro quadrático médio como função custo, portanto, quanto menor o valor do erro, melhor a capacidade de predição. A avaliação da função custo ocorre em duas categorias importantes: acertos, que avaliam hipóteses verdadeiras e falsas preditas corretamente; e perdas, que avaliam hipóteses verdadeiras e falsas preditas incorretamente, os chamados falsos positivos/negativos (MARQUES, 2018).

O algoritmo de otimização é o responsável pela minimização da função custo através do treinamento da rede. Uma das técnicas mais utilizadas é a do gradiente descendente, um método iterativo de busca de mínimos locais/global (MARQUES, 2018).

Este trabalho busca identificar tipos de sólidos e classificá-los segundo um rótulo pré-definido, portanto, pode ser alocado dentro de problemas de classificação. Um dos métodos com grande aplicabilidade a esse tipo de problema são as redes neurais artificiais (ANN's) tipo *feedforward*, onde as mais populares são as *Multi Layers Perceptrons* (MLP's).

Esse tipo de rede tem a informação fluindo da entrada para a saída, sem recorrências e sua arquitetura é composta de camada de entrada, camadas intermediárias e camada de saída. Em geral, o tamanho da camada de entrada equivale ao número de variáveis de entrada do banco de dados e o tamanho da camada de saída, ao número de classes possíveis. O número de camadas intermediárias, bem como a quantidade de neurônios em cada uma delas, são hiperparâmetros da rede, ou seja, são fatores de grande influência para uma boa resposta, mas que não podem ser ajustados no treinamento (GROSSI, 2017).

MLP's são aplicáveis a uma enorme gama de problemas, mas a solução deles pode não ser alcançada por causa de problemas como *underfitting* e *overfitting*. O *underfitting* ocorre quando o erro de treinamento é alto, o que pode acontecer caso a rede não possua neurônios suficientes em sua arquitetura para modelar o problema. O *overfitting* ocorre quando o erro do treinamento é baixo, mas do teste e validação são altos, o que acontece quando a alta performance de predição é alcançada no treinamento, mas o modelo apresenta baixa capacidade de generalização, ou seja, não ajusta corretamente dados novos (GROSSI, 2017; MARQUES, 2018). É exemplificado na **Erro! Fonte de referência não encontrada.** como ocorre cada um desses erros para o caso de uma dispersão de pontos, onde o problema tem uma entrada  $x$  e uma saída  $y$ .

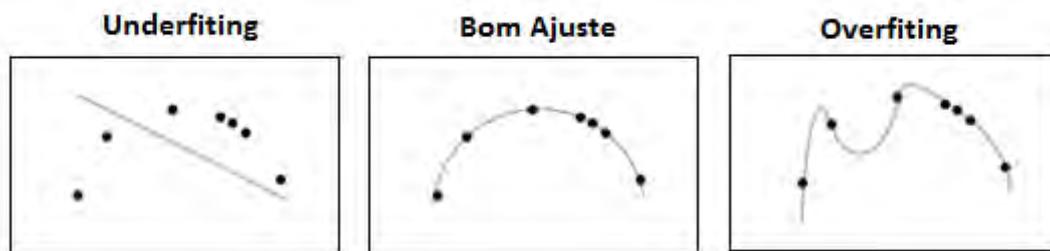


Figura 48. Exemplo de *underfitting* e *overfitting*.  
Fonte: Adaptado de MARQUES, 2018.

Problemas com vídeos e imagens, considerados dados estruturados, devem ser tratados com mais cuidado. Uma imagem é formada por *pixels*, que por sua vez são representados por uma coordenada  $(x,y)$  e uma intensidade de cores. Sendo assim, cada *pixel* pode ser visto como um vetor que armazena esses elementos. Como os *pixels* possuem uma relação espacial entre si, cada um deles em cada camada de cores seria, então, representado por um neurônio na entrada da MLP.

Para exemplificar a estrutura necessária para processar uma imagem usando uma MLP, considere uma imagem colorida de tamanho  $256 \times 256 \times 3$ . Essa imagem é muito pequena comparada às imagens utilizadas atualmente para fins científicos, mas ainda assim precisaria de 196.608 parâmetros para conectar todas as entradas a um único neurônio na camada intermediária. Esse único neurônio não seria suficiente para resolver o problema de classificação, levando a um *underfitting*. Por outro lado, mais neurônios, como por exemplo 10, demandariam um custo computacional altíssimo para o processamento de mais de um milhão de parâmetros, sem falar da alta possibilidade de *overfitting* à medida que mais neurônios e mais camadas são acrescentadas à arquitetura da rede. Para resolver esse tipo de problema são utilizadas técnicas de aprendizado profundo, mais conhecido pelo termo *deep learning*.

### 5.6.1 Aprendizado profundo

Quando as técnicas convencionais de *machine learning* se tornam limitadas para a resolução de problemas, são aplicadas técnicas de *deep learning*, capazes de processar dados naturais em sua forma bruta, muitas vezes sem pré-tratamento. A proposta é resolver problemas complexos utilizando um número maior de camadas que as MLP's sem que haja o *overfitting* (LECUN et al., 2015; MARQUES, 2018).

Sendo assim, o aprendizado profundo é um segmento do aprendizado de máquina que tem como objetivo fazer com que computadores interpretem um volume muito maior de dados de forma mais natural, mais próxima da interpretação biológica de um ser humano.

Para problemas que envolvam o processamento de imagens é preciso que o modelo tenha baixa sensibilidade para variações de posição, orientação e iluminação de um mesmo objeto em cenas diferentes. Ao mesmo tempo, deve possuir alta sensibilidade para variações mínimas que diferenciem dois objetos distintos. Um bom exemplo é a comparação entre um cão branco da raça *Samoyed* e um lobo branco (**Erro! Fonte de referência não encontrada.**).



(A)



(B)

Figura 49. (A) Cão branco da raça *Samoyed*; (B) Lobo branco.

Um classificador raso não conseguiria diferenciar os dois animais somente a nível de intensidade de *pixels* e por esse motivo, para que os classificadores se tornem mais “poderosos”, mais eficientes, estes são projetados utilizando uma arquitetura de aprendizagem profunda. Isto é, sua arquitetura possui um conjunto inicial de módulos simples de aprendizagem de uso geral, principal vantagem desta aplicação e depois, um sistema de classificação (LECUN et al., 2015).

Os módulos de aprendizagem são os responsáveis pela elevação dos níveis de representação a níveis abstratos e cada módulo é responsável por uma transformação. Uma

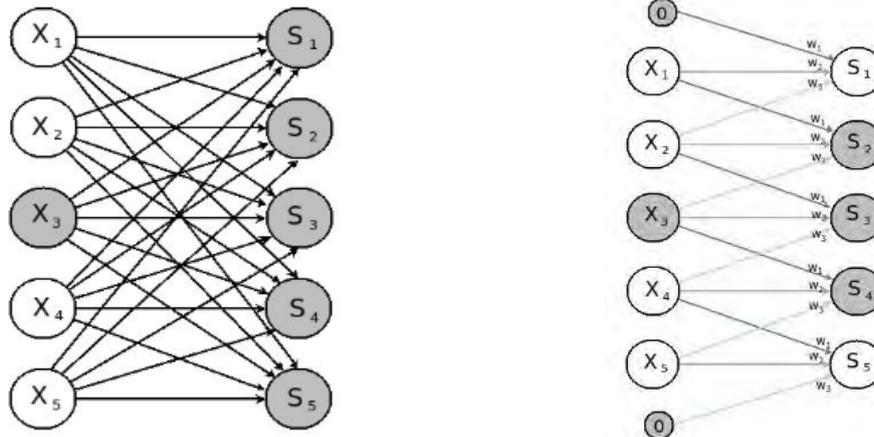
imagem é apresentada aos módulos como um conjunto de *pixels* que carregam valores. Em uma primeira transformação, por exemplo, poderia ser detectada a presença ou não de arestas em determinadas orientações na imagem. Uma segunda transformação poderia detectar combinações de arestas que se repetem. Uma terceira transformação poderia associar as combinações a partes de objetos e assim sucessivamente. Funções muito complexas, oriundas de problemas de classificação com alto grau de dificuldade, podem ser aprendidas com número suficiente dessas transformações (LECUN et al., 2015). O maior exemplo de aplicação de sucesso são as redes neurais convolucionais.

### 5.6.2 Redes neurais convolucionais

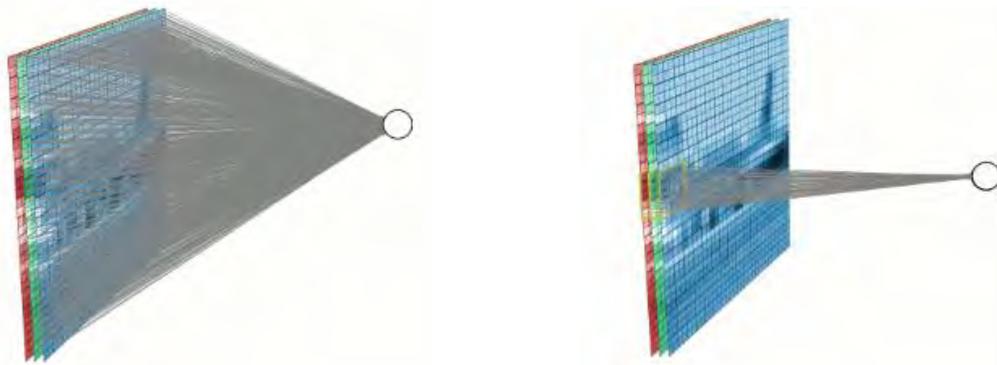
Redes Neurais Convolucionais (CNN) podem ser descritas como redes neurais *feedforward* que possuem a capacidade de tratar dados que sejam dependentes espacialmente entre si, como som e imagens. A arquitetura das CNN é composta por um módulo de aprendizado geral com camadas convolucionais e de *pooling* e um sistema de classificação formado por uma ou mais camadas completamente conectadas, muito semelhantes a MLP's (FARIA, 2018; MARQUES, 2018).

Para que a solução de problemas seja alcançada com um número de parâmetros muito menor, comparados às MLP's, são utilizadas três estratégias no módulo de aprendizagem geral: interações esparsas, compartilhamento de parâmetros e representações equivalentes (LECUN et al., 2015; MARQUES, 2018).

O conceito de interações esparsas faz com que os neurônios da camada intermediária se conectem a apenas um grupo de *pixels* e não a todos eles. Isso é feito dividindo a imagem de entrada em regiões, os chamados campos receptivos, que serão submetidos às transformações (FARIA, 2018; MARQUES, 2018). A **Erro! Fonte de referência não encontrada.** ilustra a diferença entre os dois tipos de conexão apresentados.



(A)



(B)

Figura 50. (A) ANN com camadas completamente conectadas. (B) ANN com interações esparsas entre camada de entrada e intermediária.

Fonte: Adaptado de MARQUES, 2018.

Para exemplificar o impacto desse tipo de interação na redução de parâmetros, voltemos ao exemplo de uma imagem  $256 \times 256 \times 3$ . Utilizando o conceito de camadas completamente conectadas seriam necessários 196.608 parâmetros para conectar todas as entradas a um único neurônio na camada intermediária.

Utilizando o conceito de interações esparsas, pode-se definir, por exemplo, um campo receptivo de tamanho  $5 \times 5 \times 3$ , utilizando a mesma profundidade da imagem do exemplo, com 75 parâmetros associados a cada campo. Dessa forma, para cobrir toda a imagem, seriam necessários aproximadamente 2.704 neurônios, considerando a aproximação de 52 campos ao longo da altura e 52 campos em largura. Sendo assim, para conectar a camada de entrada a 2.704 neurônios na camada intermediária são utilizados 202.800 parâmetros. Caso as camadas fossem completamente conectadas, o número equivalente de parâmetros para os mesmos 2.704 neurônios seria de 531,6 milhões de parâmetros, número 2.600 vezes maior.

Em uma MLP, são atribuídos pesos às informações quando passam de uma camada a outra e estes são ajustáveis durante o treinamento. O mesmo ocorre para uma CNN, porém, pelo volume de informação, esses pesos são calculados para um campo receptivo e posteriormente aplicados para toda a imagem e esse é o fundamento do compartilhamento de parâmetros. De forma simples, um filtro de mesmo tamanho do campo receptivo é definido para realizar as transformações e este percorre toda a imagem aplicando os mesmos valores para todos os campos. Como os parâmetros são compartilhados, mudanças na entrada podem alterar significativamente a saída e isso se chama representação equivalente (MARQUES, 2018).

### 5.6.2.1 Camadas de convolução

A transformação entre o campo receptivo e o filtro é uma operação de convolução, dessa forma, a camada responsável por esse tipo de transformação é denominada Camada de Convolução, que realiza a extração das características da imagem.

Para que seja repassada para as próximas camadas, a informação de cada campo deve ser relevante para a resolução do problema, ou seja, é preciso que seja detectada alguma característica importante e isso é avaliado por uma função de ativação. Assim como em MLP's, depois da atribuição dos pesos ocorre a adição de *bias*, que são fornecidos como entrada à função de ativação escolhida. Caso o valor alcançado seja maior que um determinado limiar, o neurônio é ativado e a informação segue para a camada seguinte. Caso o valor não atinja esse limiar, o neurônio é desativado (FARIA, 2018; SOUSA, 2019).

O resultado obtido após a ponderação pela função de ativação forma o chamado mapa de características, que será repassado para as próximas camadas. Ele possui equivalência espacial preservada, ou seja, a resposta à ativação é alocada em posição equivalente ao campo receptivo da imagem (SOUSA, 2019).

A **Erro! Fonte de referência não encontrada.** mostra uma imagem com o algarismo 3 representado nos três canais de cores RGB, fornecida como entrada para uma CNN. Em uma primeira operação de convolução, são destacados dois campos receptivos, a que foram atribuídas ativações positivas. Um exemplo de filtro utilizado na operação é de detecção de arestas verticais. As setas tracejadas indicam a posição em que as respostas dessas ativações foram alocadas, exemplificando o mapeamento das ativações. Em uma segunda operação, por exemplo com filtros de detecção de arestas horizontais, foram destacados três campos receptivos. Vale ressaltar que a entrada da segunda camada de convolução não é mais a imagem de entrada e sim o primeiro mapa de características gerado (SOUSA, 2019).

Não há uma regra que defina o número de camadas de convolução necessárias para a resolução de cada problema. Esse número depende da complexidade da imagem e aumenta até que o objeto de interesse possa ser detectado/ reconhecido com sucesso.

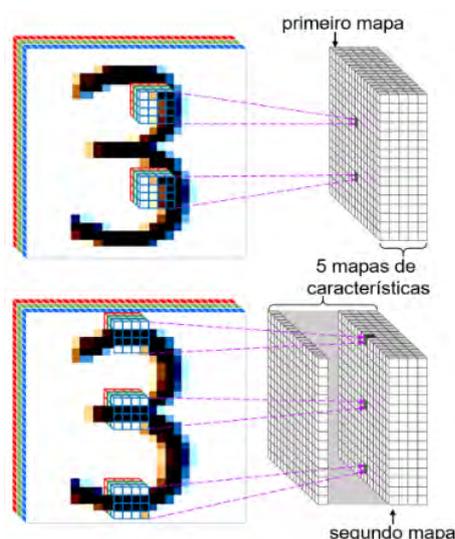


Figura 51. (A) Formação dos mapas de características.

Fonte: SOUSA, 2019.

### Camadas de *Pooling*

Camadas de *pooling* normalmente aparecem na arquitetura das CNN's após as camadas de convolução. São aplicadas aos mapas de características com a finalidade de destacar qual informação, de fato, é a mais importante e significativa para a detecção dos objetos (FARIA, 2018; SOUSA, 2019).

Reduzem a dimensionalidade do mapa de características em relação a altura e largura através de operações de agrupamento, mas mantém sua profundidade, que se relaciona com o número de filtros aplicados na operação de convolução. Essa redução espacial ocasiona a diminuição do número de parâmetros das camadas seguintes, além de contribuir para a invariância a translação e iluminação (MARQUES, 2018; SOUSA, 2019).

Para essa operação são utilizados filtros de tamanho pré-definido que percorrem a imagem aplicando alguma função dentro de suas dimensões e a resposta origina um mapa de características ressaltadas. Dentre as funções mais populares estão a *maxpooling*, *sumpooling* e

*averagepooling*, que calculam, respectivamente, o valor máximo, a soma de valores e a média dos valores dos *pixels* da região delimitada (FARIA, 2018). **A Erro! Fonte de referência não encontrada.** exemplifica redução da dimensionalidade utilizando a função *maxpooling*.

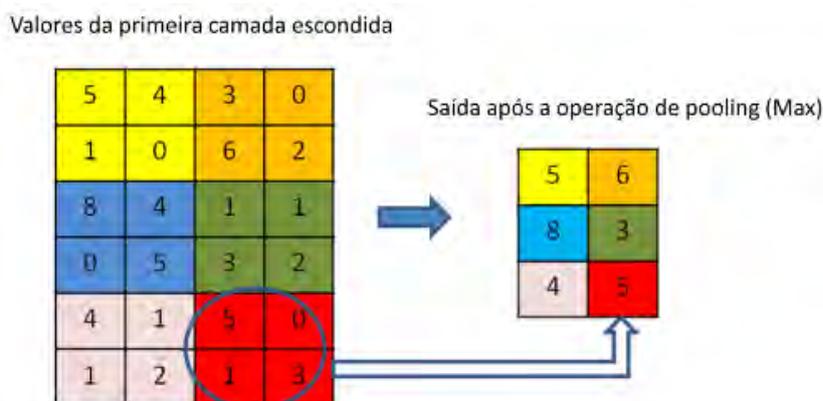


Figura 52. Aplicação de uma camada de *pooling* com função máximo.  
Fonte: Adaptado de FARIA, 2018.

### 5.6.2.2 Camadas completamente conectadas

As camadas completamente conectadas, chamadas *fully connected*, são o elemento final de uma rede convolucional e são responsáveis pela classificação do objeto detectado em rótulos pré definidos pelo usuário. O conjunto delas funciona como uma MLP, onde as entradas são representadas por um vetor de características e as saídas equivalem às classes possíveis para o objeto (FARIA, 2018; MARQUES, 2018; SOUSA, 2019).

Três funções merecem um destaque especial nas CNN's: *flatten*, *dropout* e *softmax*.

A função *flatten* é aplicada sempre entre as camadas convolucionais e a primeira camada completamente conectada e ela é a responsável pela transformação do mapa de características final em vetor de características (JURASZEK, 2014).

A função *dropout* é utilizada para ajustar o nível de complexidade do modelo e pode ser aplicada tanto às camadas convolucionais quando as camadas de classificação, mas é mais comumente associada a esta última. Seu objetivo é desativar aleatoriamente conjuntos diferentes de neurônios a cada iteração da etapa de treinamento, o que faz com que cada grupo de neurônios se relacione com características diferentes. Além da redução de parâmetro, tem como consequência a redução da possibilidade de *overfitting* e a redução de ruídos que não são muito frequentes. A quantidade de neurônios desativada é um hiperparâmetro da rede, mas em geral é aplicada um desligamento de 50% (JURASZEK, 2014; MARQUES, 2018).

A função *softmax* é o método mais aplicado para quantificar a saída da rede. É aplicada ao final da CNN e tem como objetivo forçar que a soma das probabilidades do objeto pertencer a cada uma das classes seja igual a um. Dessa forma, a classe que obtiver o maior valor de probabilidade será a classe equivalente para o objeto detectados. Isso aumenta estatisticamente a boa performance de classificação (MARQUES, 2018).

Para que a CNN seja eficaz na detecção de objetos são necessários dois tipos de treinamento, que ajustam os módulos de aprendizagem geral e as camadas completamente conectadas.

O treinamento dos módulos é feito com o ajuste dos filtros, que devem gerar um sinal ativado quando determinadas características estiverem presentes no campo receptivo. O objetivo desse treinamento é fazer com que todas as características possíveis sejam extraídas da imagem, fornecendo à parte completamente conectada toda a informação contida na imagem de entrada. Essas características, como bordas e arestas, podem ser encontradas em uma infinidade de objetos, portanto, para que a rede tenha uma boa performance na extração, é necessário que a CNN “experimente” a maior variabilidade de imagens possíveis, daí o termo “aprendizado geral” (JURASZEK, 2014).

As camadas de classificação são treinadas da mesma forma que MLP’s, utilizando o algoritmo *backpropagation*. A entrada da camada completamente conectada é o vetor de características obtido nas etapas de convolução, com seus filtros já definidos pelo primeiro treinamento. Dessa forma, um conjunto de características é associado a um rótulo e os pesos dessas conexões são ajustados para o grupo específico de objetos de interesse do estudo (JURASZEK, 2014).

A segunda parte do treinamento é específica de cada problema, tendo que ser repetida a cada nova abordagem, ou em casos que o banco de dados seja modificado de forma expressiva. Em contrapartida, a primeira parte do treinamento se relaciona a atributos normalmente extraídos em qualquer problema que envolva processamento de imagens, portanto, os módulos treinados podem ser aproveitados para vários tipos de problemas diferentes, o chamado *transfer learning* (MARQUES, 2018).

### 5.6.2.3 Modelos pré-treinados

Por definição, o *transfer learning* representa um modelo pré-treinado em uma rede consideravelmente grande, com pesos e parâmetros calculados, que é finamente ajustado para um outro problema específico. Dessa forma, o ajuste fino recalcula todos os parâmetros das camadas completamente conectadas com o algoritmo *backpropagation*, enquanto os pesos das camadas convolucionais permanecem inalterados, congelados (FLORINDO, 2018). A seguir serão apresentadas as CNN’s mais utilizadas como modelos pré-treinados.

LeCun et al. (1998) publicaram um trabalho pioneiro, a primeira rede neural convolucional, *LeNet*, com a proposta de detectar algarismos manuscritos. A CNN foi treinada com várias imagens de números de 0 a 9 escritos a mão fornecidos individualmente e o teste foi feito com a leitura de códigos postais, também escritos a mão. A arquitetura da rede era composta por 3 camadas de pesos ajustáveis: camadas de convolução com função de ativação tangente hiperbólica, camadas de *pooling* médio e uma camada completamente conectada MLP. O trabalho mostrou que as CNN’s superavam outros métodos de identificação de dígitos, mas não ganhou popularidade na época devido à dificuldade de encontrar *hardwares* para o processamento. Apesar disso, serviu como base para o desenvolvimento de outras CNN’s mais poderosas (MARQUES, 2018). **A Erro! Fonte de referência não encontrada.** ilustra a arquitetura proposta para a *LeNet*.

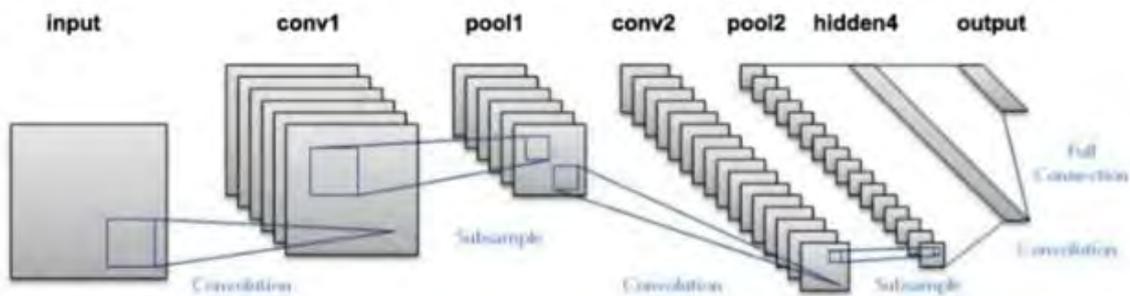


Figura 53. Arquitetura da CNN *LeNet*.  
 Fonte: ANWAR, 2019.

Em 2007, o projeto *ImageNet*, banco de imagens organizado segundo hierarquia do *WordNet*, um banco de palavras, começou a ser construído e foi apresentado para a comunidade acadêmica em 2009, em uma Conferência de Visão Computacional na Flórida. É um banco colaborativo com intuito de alavancar pesquisas no segmento de Visão Computacional, ou seja, está em crescente atualização por diversos pesquisadores do mundo inteiro. Atualmente possui mais de 14 milhões de imagens rotuladas em mais de 21 mil categorias diferentes, em que cada categoria rotulada por um substantivo possui pelo menos 1.000 imagens (IMAGENET<sup>1</sup> – Stanford).

Anualmente ocorre um evento de referência em reconhecimento de imagens, o chamado *ImageNet Large-Scale Visual Recognition Challenge* (ILSVRC), com primeira edição em 2010, que avalia algoritmos de detecção de objetos a partir do *ImageNet*. Antes disso outros eventos na mesma área utilizavam bancos de imagens muito menores, de certa de 20.000 imagens. A cada ano uma proposta de reconhecimento diferente é feita e os participantes que apresentarem os melhores desempenhos e algoritmos mais inovadores são convidados a expor em *workshop* seus métodos e resultados. Justamente nesse evento surgiram as principais redes neurais convolucionais pré-treinadas, muito utilizadas em diversos segmentos da indústria (IMAGENET<sup>2</sup> – Stanford).

Uma rede de muito destaque é a *AlexNet*, vencedora do ILSVRC – 2012. Essa CNN foi uma das primeiras a aumentar significativamente a precisão, alcançando a marca de 84,7% de acerto, contra o alcance máximo conseguido nos anos anteriores em torno de 75%. É inspirada na rede *LeNet*, mas com maior profundidade, essencial para se alto desempenho. Sua arquitetura (**Erro! Fonte de referência não encontrada.**) é composta por 8 camadas de pesos ajustáveis: cinco camadas convolucionais e três camadas completamente conectadas (FC's). A principal diferença estrutural da entre ela e a *LeNet*, além do tamanho, é que nem toda camada convolucional é seguida de uma camada de *maxpooling*. As camadas convolucionais passaram a realizar operações com mais filtros e de tamanhos diferentes (11x11, 5x5 e 3x3). Além disso, recebeu uma camada *dropout* após as FC's, o que teve como consequência a redução de parâmetros. Outro ajuste importante se deu nas funções de ativação, todas lineares no lugar das funções padrão tangente hiperbólica ou sigmoide, o que fez com que o treinamento fosse muito mais rápido. O treinamento da rede foi feito em duas GPU's e demorou 6 dias (MARQUES, 2018; ANWAR, 2019).

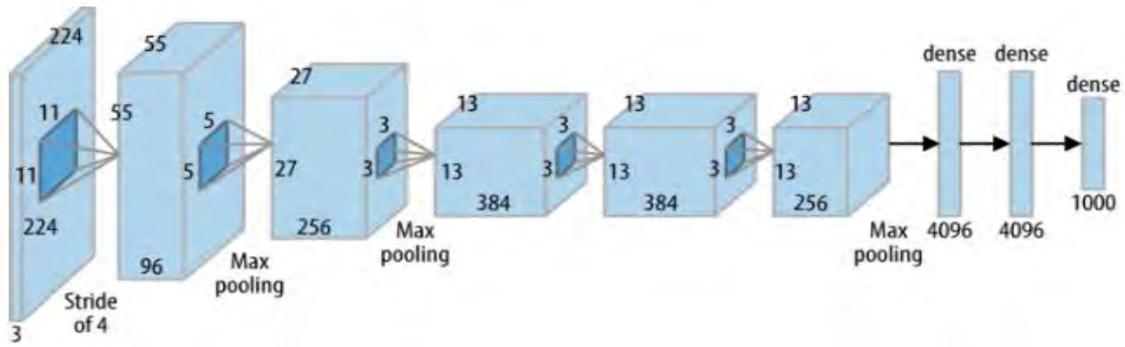


Figura 54. Arquitetura da CNN *AlexNet*.  
 Fonte: ANWAR, 2019.

Em 2014 um outro resultado surpreendente foi anunciado: a rede *GoogLeNet* foi a vencedora do ILSVRC com uma taxa de precisão de 93,3%. Essa CNN também se inspirou na pioneira *LeNet*, mas implementou o chamado módulo *Inception*, que se baseia em várias convoluções muito pequenas, que reduzem significativamente o número de parâmetros em relação a *AlexNet*. Sua arquitetura é muito mais profunda, apresentando 22 camadas de pesos ajustáveis e apresenta duas diferenças em relação a *AlexNet*. A primeira delas é a utilização de camadas de *averagepooling*. A segunda é a possibilidade de obtenção de saídas independentes em três pontos diferentes da rede, com o resultado podendo ser calculado a partir do agrupamento das três respostas fornecidas (MARQUES, 2018; ANWAR, 2019).

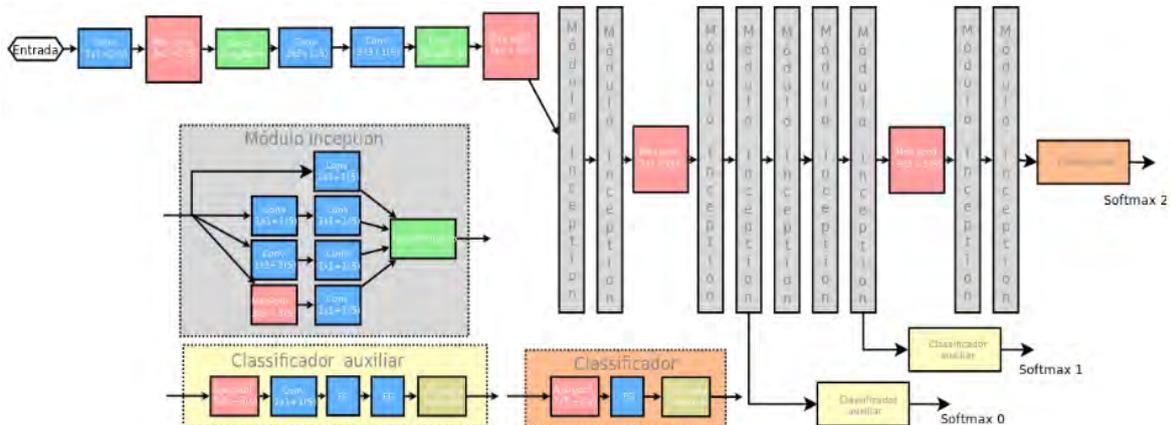


Figura 55. Arquitetura da CNN *GoogLeNet*.  
 Fonte: MARQUES, 2018.

Uma outra rede de relevância também apresentada no ILSVRC – 2014 é a *VGGNet*, com 19 camadas de pesos ajustáveis (**Erro! Fonte de referência não encontrada.**), que modificou a *AlexNet* de forma que o tamanho dos filtros fosse fixo, todos 3x3. Essa melhoria diminui o custo computacional associado ao ajuste de cada campo receptivo e permite que mais características possam ser detectadas a cada operação. Em contrapartida, por possuir camadas convolucionais muito largas, pela aplicação de filtros pequenos, tem um custo computacional total alto. Alcança precisão de 92,3%, mas precisa de 2 a 3 semanas de processamento em 4 GPU's para finalizar o treinamento.

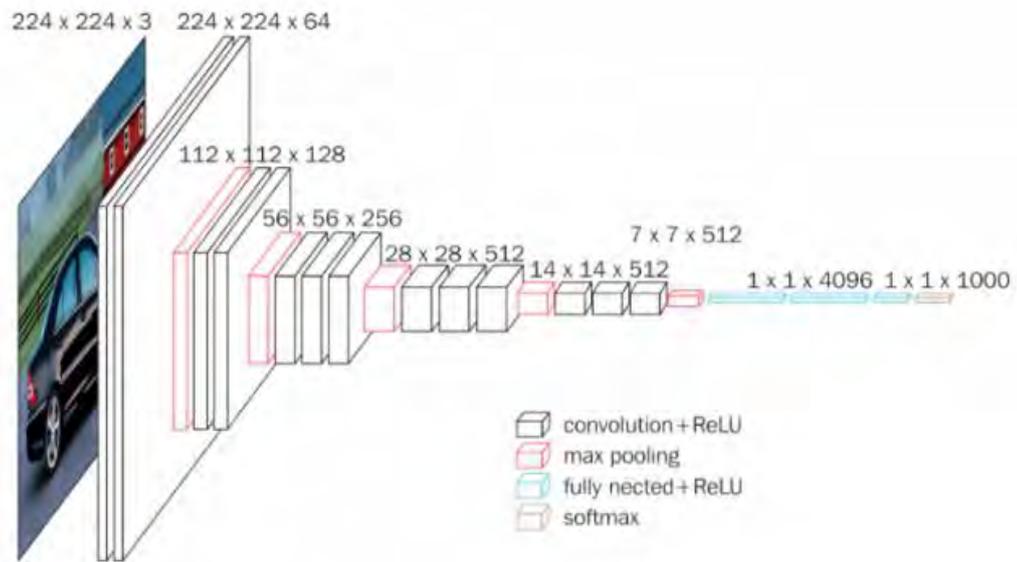


Figura 56. Arquitetura da CNN *VGGNet*.  
 Fonte: ANWAR, 2019.

## 6 METODOLOGIA

A metodologia proposta neste trabalho foi dividida em três etapas: (i) ensaios experimentais no Laboratório de escoamento de Fluidos Giulio Massarani da Universidade Federal Rural do Rio de Janeiro (LEF/UFRRJ), que envolveram a construção da unidade experimental onde foram realizados os ensaios de escoamento de sólidos variados; (ii) desenvolvimento e validação dos aplicativos de monitoramento e apoio ao geólogo e; (iii) avaliação dos aplicativos desenvolvidos na etapa anterior em vídeos da operação de uma peneira em escala piloto, obtidos no Laboratório da Faculdade de Engenharia Química da Universidade Federal de Uberlândia.

### 6.1 Ensaios Experimentais

#### 6.1.1 Unidade experimental

A unidade experimental ilustrada na Figura 57 é composta por um silo de armazenamento de sólidos no formato de pirâmide invertida acoplado à uma calha metálica, por onde o escoamento ocorre. Adjacente ao silo encontra-se fixado um dosador vibratório de média capacidade (Figura 58), marca MVL vibradores industriais LTDA, que varia a intensidade de vibração de 0 a 100%. Ao final da calha, encontra-se um reservatório captador de sólidos e, a uma distância de 20cm, um tripé com uma câmera filmadora NIKON D5100 DSLR com sensor óptico CMOS de 16,2 megapixels e capacidade de filmar em alta definição, posicionada a um ângulo de aproximadamente 45° em relação a calha.



Figura 57. Unidade Experimental.  
Fonte: O autor.



Figura 58. Dosador Vibratório.  
Fonte: O autor.

#### 6.1.2 Grupos de sólidos avaliados

Foram estudados cinco grupos de sólidos diferentes, onde o tipo de material pertencente ao grupo seguinte foi determinado a partir dos resultados obtidos com o grupo anterior. Isso possibilitou uma sequência lógica na evolução das técnicas empregadas e na subsequente obtenção dos resultados.

### 6.1.2.1 Grupo I

Em um primeiro momento, para prova de conceito, formando o Grupo I de análise (Figura 59) foram utilizados grãos e cereais: milho, arroz, feijão e ervilhas. Esse tipo de sólido foi escolhido por conta da uniformidade geométrica e de características texturais presentes nos constituintes de cada amostra.

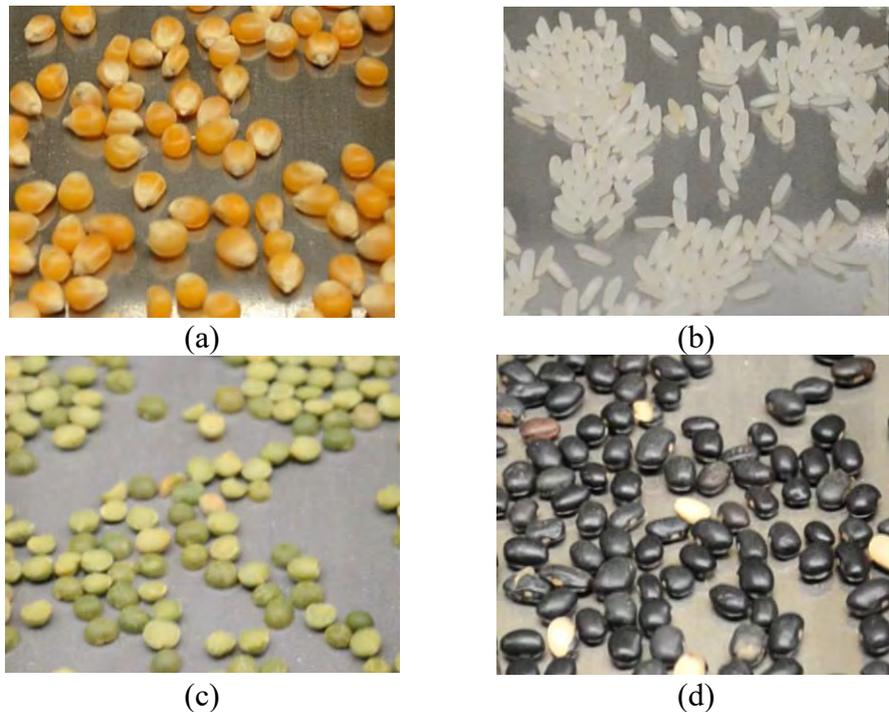


Figura 59. Grupo I: (a) milho, (b) arroz, (c) ervilhas e (d) feijão.  
Fonte: O autor.

### 6.1.2.2 Grupo II

O segundo grupo utilizou fragmentos de quartzo coloridos artificialmente, adquiridos como pedras de aquário (Figura 60). A escolha desse material teve como objetivo testar os algoritmos com sólidos mais assemelhados aos cascalhos extraídos dos poços de petróleo. Foram definidos três subgrupos de acordo com o tamanho, *(i)* pequeno, *(ii)* médio e *(iii)* grande (Figura 61). Os tamanhos médios de cada subgrupo foram obtidos por medição com paquímetro para uma amostra de dez fragmentos por subgrupo.



Figura 60. Quartzo colorido artificialmente.  
Fonte: O autor.



Figura 61. Subgrupos de quartzo divididos por tamanho.  
Fonte: O autor.

O algoritmo desenvolvido para este grupo foi testado posteriormente em um vídeo de uma peneira vibratória real, obtido em sonda de perfuração de petróleo, para avaliação da etapa de processamento de imagens. Os resultados obtidos foram muito encorajadores.

### 6.1.2.3 Grupo III

Definiu-se como Grupo III fragmentos de areia, mármore, granito e quartzo colorido artificialmente (Figura 62) em tamanhos variados. Os sólidos foram submetidos a separação granulométrica com peneiras laboratoriais de aberturas 2,36mm, 1,18mm, 0,60mm, 0,30mm e 0,15mm, como mostra a Figura 63.

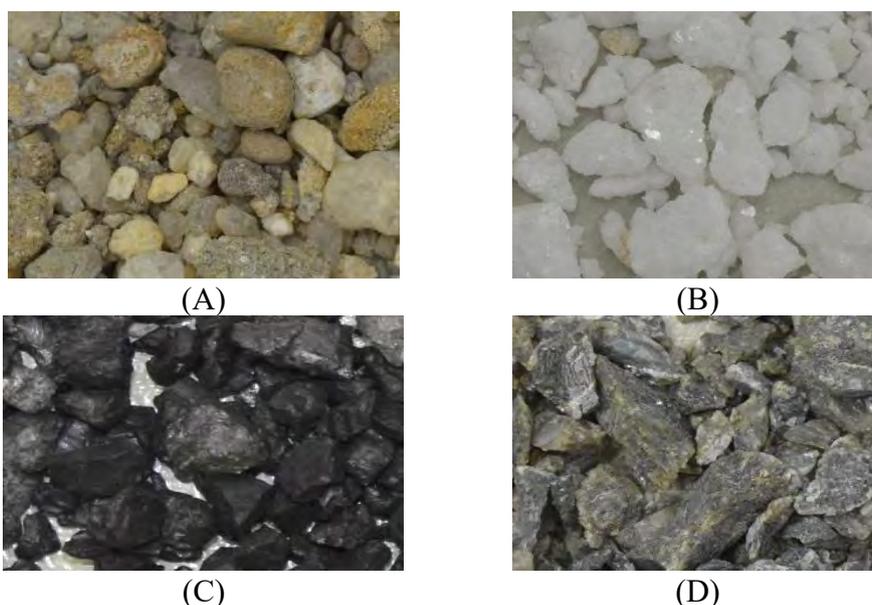


Figura 62. Grupo III: (A) areia, (B) mármore, (C) quartzo colorido artificialmente e (D) granito.

Fonte: O autor.

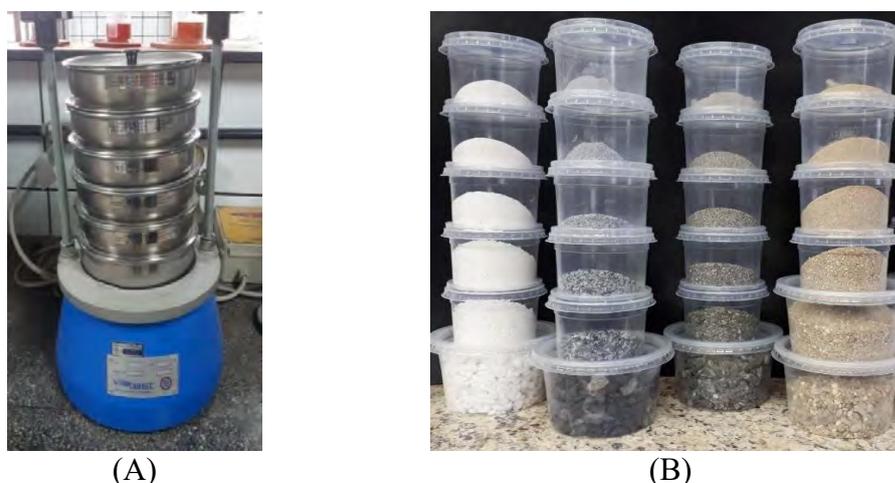


Figura 63. (A) Conjunto de peneiras vibratórias laboratoriais; (B) amostras do grupo III após separação granulométrica.

Fonte: O autor.

#### 6.1.2.4 Grupo IV

O Grupo IV foi formado por cascalhos reais, fornecidos pelo Centro de Pesquisa Leopoldo Américo Miguez de Mello (CENPES), sendo possível, portanto, realizar ensaios na unidade experimental construída no LEF/UFRRJ com o tipo de material encontrado nas sondas da Petrobras. O material é composto por 10 amostras de um mesmo poço a profundidades diferentes (Figura 64), que foram fornecidas lavadas e secas. Os cascalhos também foram submetidos à mesma separação granulométrica que os fragmentos do Grupo III.

Posteriormente, o mesmo vídeo de peneira real submetido ao código proposto no Grupo II, também foi avaliado para verificação de melhorias em relação ao processamento após o aprimoramento do software obtido com o processamento dos sólidos do Grupo III. As abreviações FLH, MRG, ARN e CAL significam, respectivamente, folhelho, marga, arenito e calcita.

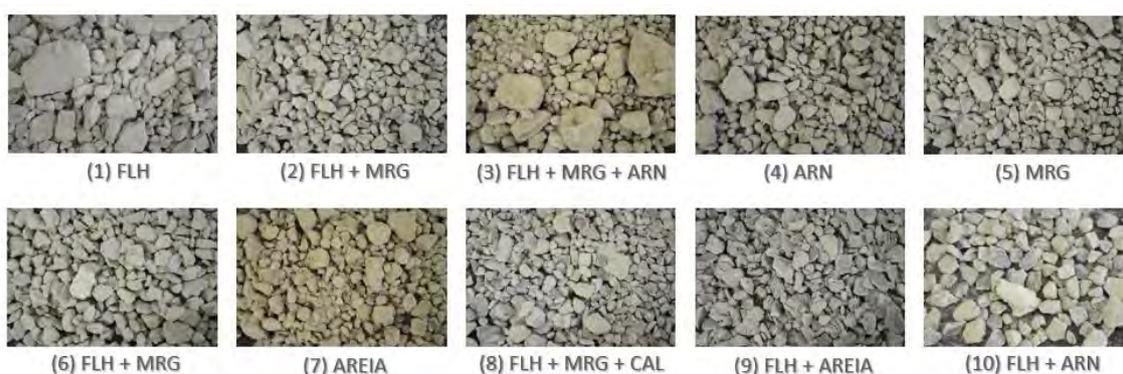


Figura 64 Amostras de cascalho de um mesmo poço separadas segundo profundidade.

Fonte: O autor.

Assim como no Grupo III, as amostras foram submetidas à separação granulométrica e os tamanhos obtidos são ilustrados na Figura 65 a seguir.

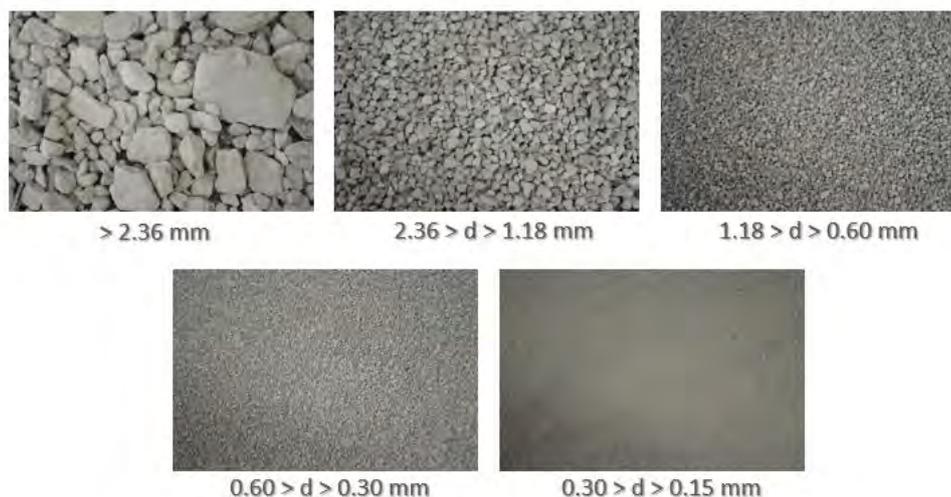


Figura 65 Amostra de cascalho separada em cinco frações granulométricas.

Fonte: O autor.

### 6.1.2.5 Grupo V

O Grupo V é composto por suspensões em concentrações variadas de areia padronizada e goma xantana 0,1%. O objetivo da análise dos vídeos obtidos com esse grupo foi avaliar situações de escoamento em via úmida, com características operacionais ainda mais similares àquelas observadas em peneiras vibratórias industriais.

Os ensaios foram realizados pelo grupo de pesquisa *Tecnologia e Inovação em Processos de Energia, Separação e Mistura*, no Laboratório da Faculdade de Engenharia Química da Universidade Federal de Uberlândia (FEQ/UFU), já apresentados no trabalho de Barbosa (2018). Os vídeos dos escoamentos utilizados na presente dissertação foram gentilmente cedidos pelo referido Grupo de Pesquisa da FEQ/UFU. Um esquema da unidade é apresentado na Figura 66.

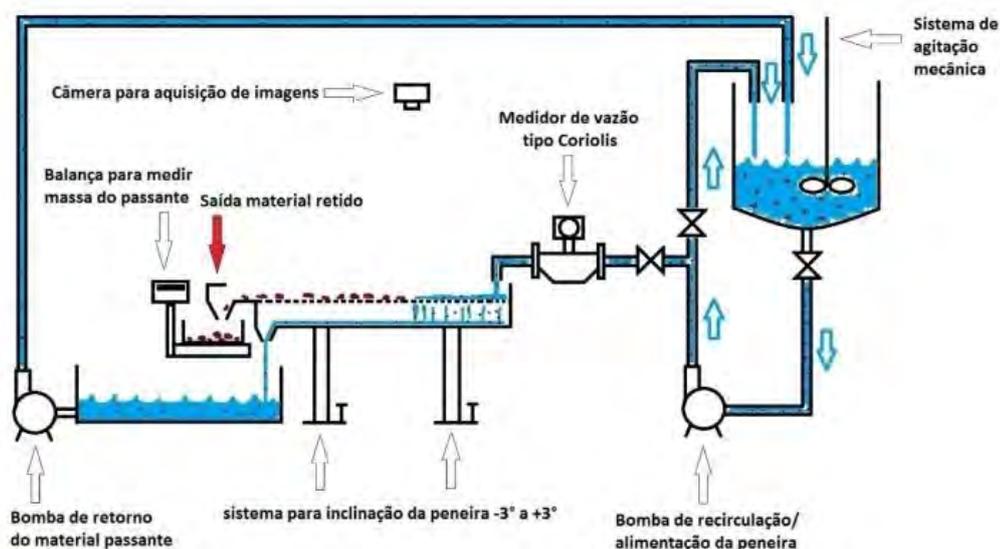


Figura 66. Circulação da suspensão de areia e goma xantana 0,1% na unidade experimental durante ensaios.

Fonte: Barbosa, 2018.

Segundo Barbosa (2018), a parte líquida da suspensão foi preparada na proporção 1g de goma xantana: 1L de água : 1mL de formol 37% e deixada sob agitação por 3 horas. Os experimentos foram realizados 24h após o preparo. A parte sólida da suspensão foi preparada com três porções mássicas iguais, com padronizações média grossa (#30), média fina (#50) e fina (#100), de forma que a granulometria na mistura variasse entre 90 e 1400  $\mu\text{m}$ .

### 6.1.3 Procedimento experimental

Os sólidos foram depositados no silo de armazenamento no LEF/UFRRJ e, na sequência, ajustou-se a abertura da saída para a calha e a intensidade de vibração em valores fixos a cada ensaio. O escoamento dos grãos foi registrado pela câmera filmadora e a vazão mássica, aferida com auxílio de balança analítica e cronômetro.

Para o Grupo I, foram depositados aproximadamente 10kg de sólidos no silo, mantendo o nível constante e ensaiadas intensidades entre 25% e 60%. Os sólidos foram avaliados isoladamente e em misturas binárias, terciárias e quaternária. Esse experimento foi utilizado para validação da unidade experimental.

Para o Grupo II, foram realizados ensaios a 30%, 35% e 40% e o objetivo principal foi a verificação da aplicação das técnicas de processamento de imagens, anteriormente utilizadas para a detecção de cereais, na detecção de sólidos irregulares. Foi proposta uma nova metodologia de ensaio com a finalidade de observar variações na vazão, aproximando as simulações da situação real nas peneiras. Os sólidos são fornecidos aos poucos ao silo ao invés de serem depositados em grande quantidade. Outra vantagem desse escoamento é o aparecimento de vazios na calha, mesmo em momentos de vazão aumentada.

Para os Grupos III e IV, foram realizados ensaios a 25%, 30% e 35% de intensidade de vibração, com a metodologia que permite observar variações de vazão. Foram avaliadas alterações na etapa de detecção de sólidos, de forma a ajustar um algoritmo que fosse capaz de identificar todos os tipos de fragmento de rocha estudados, em todos os tamanhos propostos pela separação granulométrica, dentro de uma faixa aceitável de erro, avaliada visualmente.

Os ensaios do Grupo V foram realizados por Barbosa (2018) na FEQ/UFU, segundo planejamento composto central  $3^k$  para quatro variáveis de entrada: força-g imposta à peneira, concentração volumétrica de sólidos na suspensão, vazão mássica de alimentação e inclinação da tela da peneira. O planejamento experimental totalizou 26 experimentos, todos registrados em vídeo após alcançarem estado estacionário.

Como resultado foram obtidos dados de teor de umidade residual, área da região de piscina, velocidade de escoamento na região de praia e porcentagem de área ocupada na região de praia. Os vídeos foram submetidos ao código desenvolvido e as variáveis velocidade de escoamento e porcentagem da área de secagem preenchida por sólidos foram estimadas e comparadas aos valores experimentais.

A descrição das técnicas utilizadas nas etapas de processamento de imagens e cálculo de estimativas será feita no próximo subitem.

## 6.2 Desenvolvimento dos Aplicativos de Visão Computacional

### 6.2.1 Aplicativo para monitoramento do escoamento de sólidos

Este aplicativo foi desenvolvido para realizar o processamento e análise de imagens dinâmicas obtidas a partir dos vídeos dos experimentos.

O algoritmo possui uma primeira etapa de carregamento do vídeo, que é separado em *frames* a uma frequência de 30 *frames* por segundo. Cada *frame* é submetido a uma etapa de pré-processamento que envolve transformações geométricas e projetivas de forma a obter um recorte representativo e analisável da vista superior da calha.

A etapa seguinte é a de segmentação. Os métodos de segmentação variam de um grupo para o outro e o algoritmo foi aprimorado à medida que os grupos foram analisados. O objetivo desta etapa é identificar e separar os objetos do plano de fundo segundo critérios de descontinuidade e similaridade. Todos os métodos utilizados no desenvolvimento dos aplicativos de visão computacional são descritos na fundamentação teórica desse trabalho.

- Para o Grupo I, a segmentação foi feita utilizando o algoritmo *k-means*, com número *k* de *clusters* variando de 2 a 5. Para um sólido em escoamento, tem-se  $k = 2$ , considerando o cereal e o plano de fundo. Para a mistura quaternária,  $k = 5$ , considerando os quatro grãos e o plano de fundo;
- Para o Grupo II foi utilizada a limiarização pelo método de Otsu, considerando que os sólidos e o plano de fundo possuem cores semelhantes;

- Para os Grupos III e IV, a segmentação foi feita utilizando a Transformada Bidimensional Discreta de Fourier (DFT-2D) em combinação com o Teorema da Convolução (TC) e, após esse procedimento, foi feita a binarização pelo método de Otsu com limiar adaptativo, como no Grupo II;
- Para o Grupo V foi utilizada a Transformada *Wavelet* para detecção e realce de bordas, seguida de binarização pelo método de Otsu e também segmentação por cores.

A etapa seguinte é denominada pós-processamento, sendo comum a todos os grupos. A imagem binarizada é submetida a uma abertura, que envolve duas operações sequenciais: (i) erosão e (ii) dilatação, ambas descritas no Apêndice 1. Feito isso, é realizada a extração de características.

As características morfológicas são calculadas a partir da imagem binarizada utilizando a função *regionprops* do MatLab© e realizam estimativas de propriedades geométricas de cada um dos objetos identificados na segmentação (BAKES, 2016). Os descritores utilizados, em unidade de *pixel*, são área, perímetro, circularidade, excentricidade, maior e menor eixos e caixa delimitadora que circunda o objeto. As estimativas calculadas a partir dessas propriedades são porcentagem da calha preenchida por sólidos %AP (Equação 27) e o número de grãos NGE presentes no recorte de análise do escoamento (Equação 28).

$$\%AP = \frac{\sum \text{Área}_{\text{sólidos}}}{\text{Área}_{\text{Total}}} \times 100 \quad \text{Equação 27}$$

$$NGE = \sum \frac{\text{Área}_{\text{sólidos}}}{\text{Mediana}_{\text{áreas}}} \quad \text{Equação 28}$$

Além dessas estimativas, estimou-se a velocidade média  $v_m$  (Equação 29) de escoamento dos sólidos com auxílio de detectores da biblioteca de visão computacional do MatLab©. Para tal tarefa, calculou-se a distância percorrida pelos objetos utilizando seis detectores: MSER, Harris, FAST, BRISK, ORB e SURF e o tempo corresponde à frequência de aquisição dos *frames* (1/30 s). Dos seis descritores, apenas três retornaram resultados coerentes e seus métodos estão descritos no Apêndice 1. Foram feitas validações para um objeto em escoamento, vários objetos em escoamento e considerando trechos de tamanhos diferentes da calha.

$$v_{mean} = \frac{\text{Mediana}_y}{\Delta t} \quad \text{Equação 29}$$

As características texturais foram calculadas a partir das variações locais nos valores de intensidade dos níveis de cinza dos pixels da imagem (SOUTO JUNIOR, 2010). Foi utilizada a abordagem estatística, a partir de matrizes de co-ocorrência e os descritores de Haralick aplicados foram: entropia (Equação 30), energia (Equação 31), contraste (Equação 32), homogeneidade (Equação 33) e correlação (Equação 34). As respostas normalizadas desses descritores foram avaliadas como estimadores qualitativos de vazão mássica.

$$\text{Entropy} = - \sum_{i,j} p \times \log_2(p) \quad \text{Equação 30}$$

$$Energy = \sum_{i,j} p(i,j)^2 \quad \text{Equação 31}$$

$$Contrast = \sum_{i,j} |i - j|^2 p(i,j) \quad \text{Equação 32}$$

$$Homogeneity = \sum_{i,j} \frac{p(i,j)}{1 + |i - j|} \quad \text{Equação 33}$$

$$Correlation = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p}{\sigma_i \sigma_j} \quad \text{Equação 34}$$

Na Figura 67 está ilustrado, de forma simplificada, o algoritmo utilizado para o desenvolvimento do aplicativo para cada um dos quatro grupos de sólidos estudados.

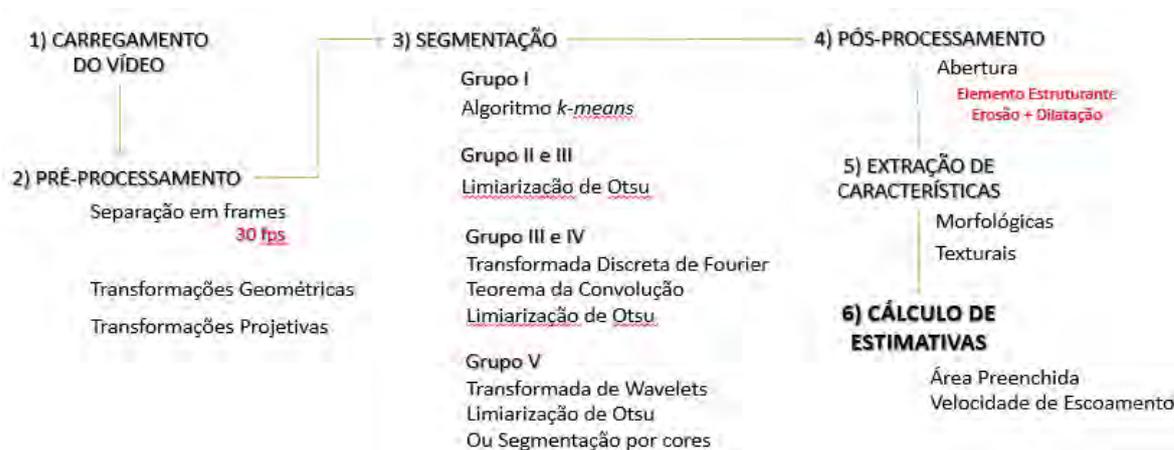


Figura 67. Algoritmo simplificado de monitoramento do escoamento de sólidos.

Fonte: O autor.

## 6.2.2 Aplicativo para apoio do geólogo

Este aplicativo foi desenvolvido para análise de imagens estáticas, obtidas a partir de fotografias e dos vídeos fornecidos pelos experimentos.

O algoritmo utiliza conceitos de *deep learning* para treinar uma rede neuronal convolucional (CNN) com o objetivo de realizar classificações dos materiais presentes em cada um dos grupos analisados. Para o Grupo I, a classificação distingue o tipo de grão/cereal em escoamento; para o Grupo IV, tamanho e tipo de sólido, dependendo da profundidade de perfuração alcançada; para o Grupo V, uma classificação qualitativa da porcentagem de preenchimento da calha. Foram testados modelos baseados na rede pré-treinada *AlexNet*, utilizando a técnica de *transfer learning*, e modelos sem treinamento prévio.

O banco de imagens foi manipulado de forma a aumentar o número de dados disponíveis e as imagens foram divididas em treinamento, teste e validação na proporção 80%, 10% e 10%, respectivamente, para os três casos. Os critérios de parada foram o número máximo de iterações igual a 500 ou a apresentação da mesma resposta durante 5 etapas de validações consecutivas. A taxa de aprendizado foi definida como 0,001 e *momentum* igual a 0,7. As CNN's receberam como entrada a imagem não processada e o resultado foi apresentado na forma de Matriz

Confusão, que apresenta os resultados na forma gráfica de classificações corretas versus classificações previstas, onde o número de acertos se concentra na diagonal principal.

Para o Grupo I, foram utilizadas imagens do escoamento em diferentes condições, medidas em dias diferentes e por câmeras diferentes, a fim de se obter a maior variabilidade possível de imagens. As cenas foram capturadas para ensaios com os grãos puros e misturas com objetivo de classificar os escoamentos segundo o tipo de sólido presente.

Para o Grupo IV, foram utilizadas imagens obtidas a partir de superfícies fotografáveis, em que foram registrados cascalhos retirados de um mesmo poço, com dez regiões de profundidades diferentes, nos cinco tamanhos previamente separados pelas peneiras. O objetivo desta rede foi classificar os cascalhos segundo tamanho e composição descrita pelo geólogo, em plataforma.

Para o Grupo V, foram utilizadas imagens dos 26 escoamentos com objetivo de avaliar a capacidade da rede de identificar a porcentagem da peneira preenchida por sólidos.

Além da identificação dos sólidos, este aplicativo também estimou descritores úteis para propriedades de tamanho e forma, como circularidade (Equação 35) e tamanho médio de partículas para os Grupos I e IV. A validação dos resultados fornecidos pelo aplicativo para o tamanho foi feita por comparação com valores obtidos experimentalmente, a partir da medição com paquímetro do maior e menor eixos de amostras representativas de cada grupo/subgrupo.

$$CR = \frac{4 \times (\text{Área do Objeto})}{\pi \times (\text{Maior eixo})^2} \quad \text{Equação 35}$$

Na Tabela 4 é apresentado, de forma resumida, o resumo das estimativas calculadas para cada grupo de sólidos analisados.

Tabela 4. Resumo das estimativas calculadas para cada grupo de sólidos.

ESTIMATIVAS	GRUPO I	GRUPO II	GRUPO III	GRUPO IV	GRUPO V
$\%AP = \frac{\sum \text{Área}_{\text{sólidos}}}{\text{Área}_{\text{Total}}} \times 100$	X	X	X	X	X
$NGE = \sum \frac{\text{Área}_{\text{sólidos}}}{\text{Mediana}_{\text{áreas}}}$	X				
<b>Maior e Menor Eixo</b>	X	X		X	
$CR = \frac{4 \times (\text{Área do Objeto})}{\pi \times (\text{Maior eixo})^2}$	X			X	
$v_{mean} = \frac{\text{Mediana}_y}{\Delta t}$			X	X	X

Fonte: O autor.

## 7 RESULTADOS E DISCUSSÃO

Os resultados serão apresentados de acordo com o grupo de sólidos estudados.

### 7.1 Grupo I

Os primeiros ensaios deste grupo foram realizados para cada um dos sólidos individualmente. Cada uma das intensidades de vibração testadas foi ensaiada dez vezes e as medidas de vazão mássica aferidas com auxílio de balança analítica e cronômetro. Na Tabela 5 são apresentados os resultados de vazão mássica média e desvios padrão.

Tabela 5. Resultados de vazão mássica dos cereais. Fonte: O autor.

Tipo de Cereal	Intensidade de Vibração (%)	Vazão Mássica Média (g/s)	Desvio Padrão	(%) Desvio
Ervilhas	25	1,7472	0,137	7,8
	30	2,9331	0,3638	12,4
	35	3,9782	0,4026	10,1
	40	8,5745	0,6800	7,9
	45	9,0036	1,002	11,1
	50	9,8943	1,369	13,8
	60	13,4300	1,5409	11,5
Arroz	30	1,2016	0,0992	8,3
	35	2,2658	0,0662	2,9
	40	3,9451	0,1802	4,6
	45	5,8888	0,3546	6,0
	50	7,9371	0,3309	4,2
	55	8,6304	0,2834	3,3
	60	10,094	0,3852	3,8
Milho	30	1,7155	0,1964	11,4
	35	3,6592	0,6114	13,7
	40	5,913	0,5629	9,5
	45	9,4342	0,9586	10,2
	50	15,123	0,5125	3,4
Feijão	25	1,0023	0,1213	12,1
	30	2,7458	0,3087	11,2
	35	5,5641	0,4458	8,0
	40	11,314	0,6713	5,9
	45	14,471	0,6918	4,8

Conforme esperado, quanto maior o valor de intensidade de vibração utilizada nos ensaios, maior a vazão mássica obtida, uma vez que mais sólidos escoam num mesmo período. O desvio padrão associado às dez medidas efetuadas para cada intensidade foi transformado em desvio percentual (coluna 5 da Tabela 5) e apresentou valores que podem sugerir que a vazão

não apresenta grande variação para este método. Na maioria dos casos, o desvio é menor que 10% e nos casos em que é maior, não ultrapassa 15%. Isso também pode ser observado durante a realização dos ensaios, em que a calha visualmente não apresenta variações significativas da quantidade de sólidos presentes ao longo do escoamento.

O objetivo desses experimentos foi simular o escoamento caótico do cascalho em peneiras vibratórias, com momentos de peneira cheia, outros de peneira vazia e por essa razão, para os grupos seguintes, foi adotada outra metodologia experimental. Dessa forma, o estudo deste grupo seguiu na direção da identificação de grãos.

### 7.1.1 Aplicativo 1 – Monitoramento do Escoamento

A primeira etapa do aplicativo envolve a detecção dos objetos e deve ser feita de forma que, independentemente de fatores como vibração e iluminação, os sólidos sejam detectados por inteiro, sem falhas nas bordas, para que forneçam dados mais próximos dos reais para o cálculo de estimativas.

O algoritmo *k-means* apresentou bom desempenho nessa tarefa porque se trata de um método de agrupamento que se baseou no espaço de cores. Sendo assim, foi possível estimar a porcentagem da calha preenchida por sólidos (%AP) e o número de grãos estimado (NGE) presentes no recorte de análise.

A %AP é a razão entre a área ocupada por todos os sólidos que estão escoando e a área total do recorte da calha de análise. A função *regionprops* calcula esse descritor geométrico a partir da imagem segmentada, em que *pixels* com intensidade 1 representam objetos e 0 o plano de fundo. Cada um dos objetos identificados como conjunto contíguo de *pixels* de valor 1 retorna como área do objeto o número de *pixels* que pertencem a esse conjunto e, sabendo o número total de elementos do recorte, é possível calcular a razão.

O número de grãos estimado também utiliza o descritor de área para a estimativa. A partir do padrão de escoamento, observou-se que apesar de alguns grãos escoarem em blocos, levando a detecção de um único objeto grande, muitos outros escoam separadamente e fornecem dados a respeito de um objeto isolado. Dessa forma, utilizou-se a mediana para estimar a área equivalente a um grão e o NGE é obtido pela razão entre a área ocupada por todos os objetos detectados e a mediana das áreas de cada objeto.

Nas Figura 68-Figura 73 a seguir são ilustrados alguns dos resultados obtidos nos escoamentos dos sólidos. Cada legenda apresenta os valores de %AP e NGE, assim como o número real de grãos NGR presentes no recorte de análise. Os grãos detectados pelo aplicativo são mostrados em branco nas imagens binarizadas, à esquerda, e contornados em vermelho na imagem original, à direita. O NGR, utilizado para o cálculo do erro, foi obtido pela contagem manual para cada um dos recortes.

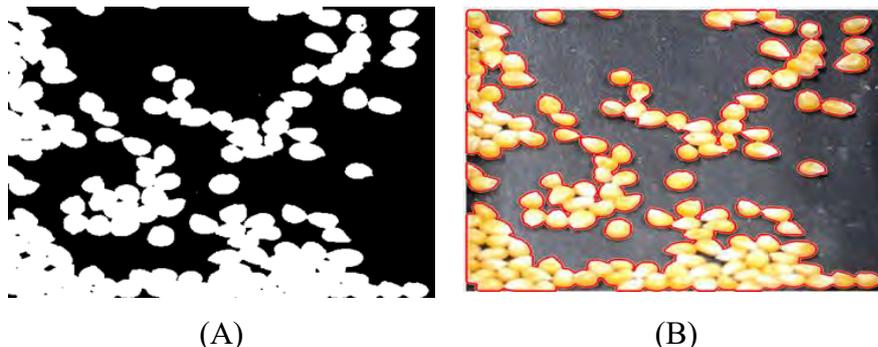


Figura 68. Milho. 30% de vibração. %AP = 37,4%. NGE = 104. NGR= 108. **Erro = 3,7%**.  
(A) Imagem binarizada, saída do algoritmo *k-means*. (B) Visualização dos objetos identificados.

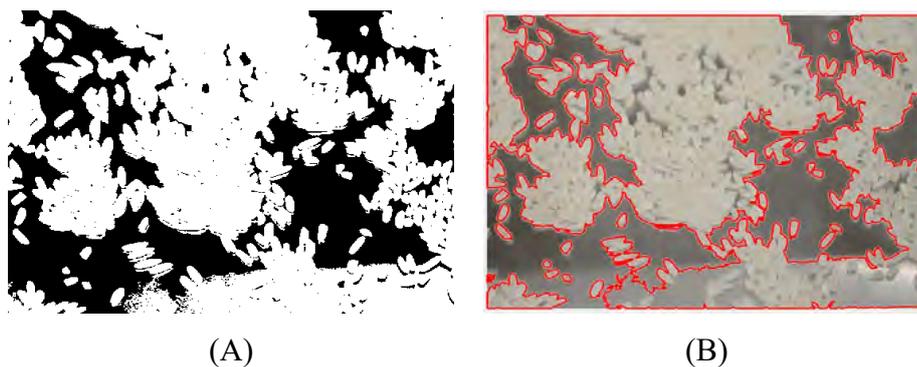


Figura 69. Arroz. 35% de vibração. %AP = 63,9%. NGE = 642. NGR= 597. **Erro = 7,5%.**  
 (A) Imagem binarizada, saída do algoritmo *k-means*. (B) Visualização dos objetos identificados.

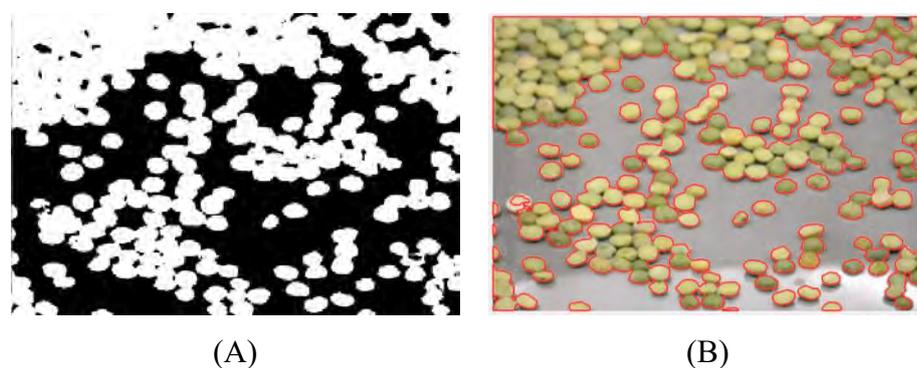


Figura 70. Ervilhas. 35% de vibração. %AP = 49,2%. NGE = 204. NGR= 228. **Erro = 5,2%.**  
 (A) Imagem binarizada, saída do algoritmo *k-means*. (B) Visualização dos objetos identificados.

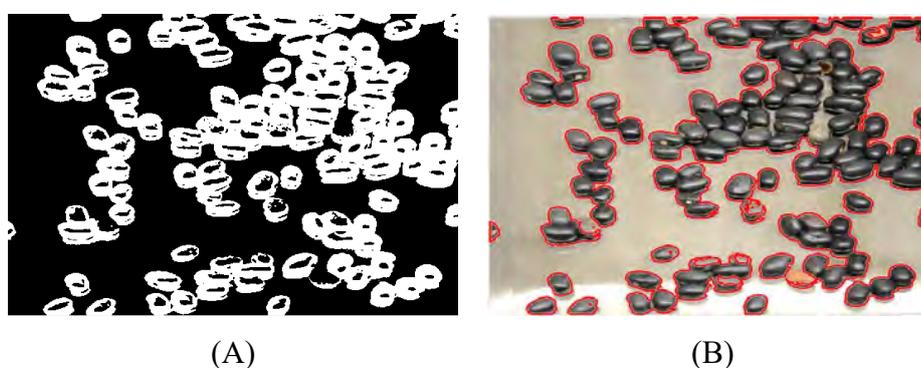


Figura 71. Feijão. 30% de vibração. %AP = 53,9%. NGE = 131. NGR= 126. **Erro = 3,9%.**  
 (A) Imagem binarizada, saída do algoritmo *k-means*. (B) Visualização dos objetos identificados.

Como mostrado nesses resultados, o aplicativo foi capaz de realizar boas estimativas para os quatro tipos de grãos/cereais avaliados individualmente. Os erros podem estar associados às etapas de processamento, com a dificuldade de detecção correta dos objetos devido a fatores como brilho da calha, por exemplo.

A mesma análise foi feita também para misturas de grãos. Percebeu-se que o aplicativo calculou de forma satisfatória a %AP, porém, o NGE nem sempre apresentou bons resultados. As imagens a seguir ilustram duas situações com desempenhos diferentes.



Figura 72. Milho e ervilhas. 40% de vibração.  
 %AP = 55,8%. NGE = 143. NGR = 137.  
 Erro = 4,4%. Fonte: O autor.



Figura 73. Milho e arroz. 40% de vibração.  
 %AP = 24,9%. NGE = 38. NGR = 74 (32 de milho e 42 de arroz). Fonte: O autor.

Na mistura ilustrada na Figura 72 o aplicativo realizou estimativas de forma satisfatória, o que pode ser atribuído ao fato de que os dois sólidos possuem tamanhos e formas semelhantes. Por outro lado, na Figura 73 tem-se dois tipos de sólidos com tamanhos e formas significativamente diferentes, o que inviabiliza a utilização da mediana para a contagem dos grãos totais.

Uma alternativa que pode solucionar esse problema é a contagem individual para cada tipo de grão. O algoritmo de segmentação retorna uma máscara, em que cada camada representa um tipo de sólido diferente. Ao invés de aplicar o algoritmo na máscara, seria possível aplicar em cada uma de suas camadas e o número de sólidos total poderá ser dado pela soma dos sólidos contado em cada uma das camadas.

O NGE precisa de valores de referência de tamanho de um sólido para aplicar nos blocos e isso funciona bem, como pôde ser visto, para sólidos regulares. Entretanto, o propósito do aplicativo é monitorar escoamento de cascalho, muitas vezes sem forma definida. Além disso, a ocorrência de fragmentos de cascalho escoando individualmente é muito baixa, o que faz com que essa estimativa (NGE) não se aplique nos grupos seguintes.

### 7.1.2 Aplicativo 2 – Classificação dos Sólidos

O segundo aplicativo utiliza imagens do escoamento para identificar o tipo de sólido e calcular algumas propriedades de um objeto pré-selecionado manualmente, como a circularidade (CR) e o tamanho médio dos grãos (TM). Para validar essas medidas foram utilizadas ervilhas. Os resultados encontrados são apresentados a seguir.

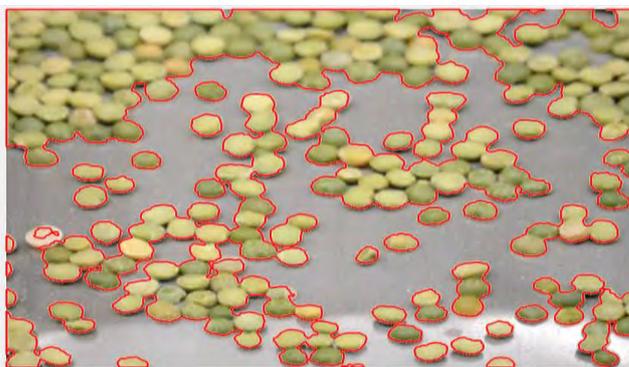


Figura 74. Escoamento de ervilhas. Fonte: O autor.

$$CR \text{ Média} = 0,9129 \pm 0,0526$$

$$TM \text{ (pixel)} = 41,74 \pm 3,90 \text{ pixels}$$

$$TM \text{ (mm)} = \mathbf{5,8 \pm 0,5mm}$$

$$\text{Tamanho Real Médio} = 6 \text{ mm}$$

Como visto, o aplicativo foi capaz de realizar estimativas de tamanho com desvio menor que 10% e medidas de circularidade compatíveis com o formato circular esperado das ervilhas.

Desvios de circularidade podem ter ocorrido pelo fato de que a aquisição da imagem é feita sob um ângulo de 45 graus em relação à calha e transformações projetivas podem levar a leves distorções no formato dos sólidos.

Para a tarefa de classificação foram fornecidas à CNN imagens com todas as possibilidades de mistura, além das imagens dos grãos puros. Na Figura 75 é apresentada a evolução do treinamento da rede neuronal. Observa-se que a CNN converge rapidamente para um modelo de alta acurácia e baixo índice de perdas, o que pode indicar alto potencial de classificação.

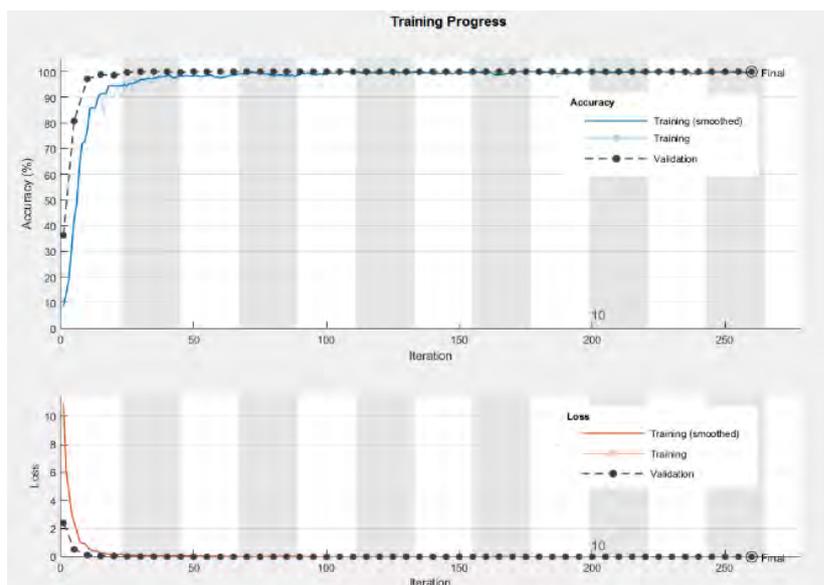


Figura 75. Treinamento supervisionado das camadas completamente conectadas da CNN proposta. Fonte: O autor.

A boa performance do *software* de visão computacional pode ser confirmada pela visualização da matriz de confusão da Figura 76. Vale ressaltar que todas as imagens utilizadas na validação e consequente construção dessa matriz, fazem parte de um conjunto de imagens desconhecidas pelo aplicativo.

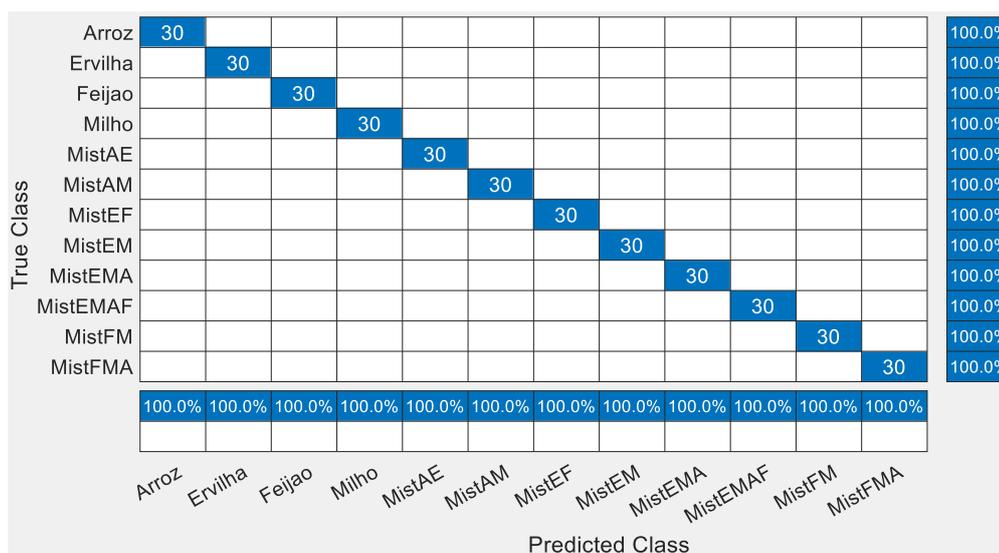


Figura 76. Matriz confusão da identificação dos grãos e suas misturas. Fonte: O autor.

O resultado apresentado afirma que o modelo proposto foi capaz de identificar o tipo de grão em escoamento, inclusive em caso de misturas. No entanto, deve-se destacar que o alto desempenho (100%) pode estar associado ao fato de os grãos possuírem características muito diferentes entre si e à pequena variabilidade no padrão das imagens disponíveis para treinamento e validação, uma vez que o banco de imagens foi construído a partir de fotografias de experimentos que utilizam o primeiro método de escoamento.

## 7.2 Grupo II

Os ensaios para esse grupo tiveram como objetivo avaliar as dificuldades do processamento de imagens para sólidos de forma e tamanho não regulares e em situação em que o sólido e o plano de fundo possuem características similares de cor.

O algoritmo *k-means* realiza uma varredura no conjunto de dados de forma que a semelhança entre dados de um mesmo *cluster* seja máxima e entre *clusters* diferentes seja mínima, o que é avaliado pelos valores de intensidade dos três canais de cores da imagem pré-processada. Como essa diferença é sutil para esse grupo, o algoritmo não respondeu de forma eficiente. A alternativa adotada foi a utilização da Limiarização de Otsu para o passo de segmentação, o que aumenta o número de etapas necessárias de pré e pós-processamento para obter uma detecção equivalente ao resultado esperado. Essas técnicas são descritas em detalhes no Apêndice 1. Na Figura 77 é representada a sequência de operações as quais a imagem deve ser submetida no pré-processamento.

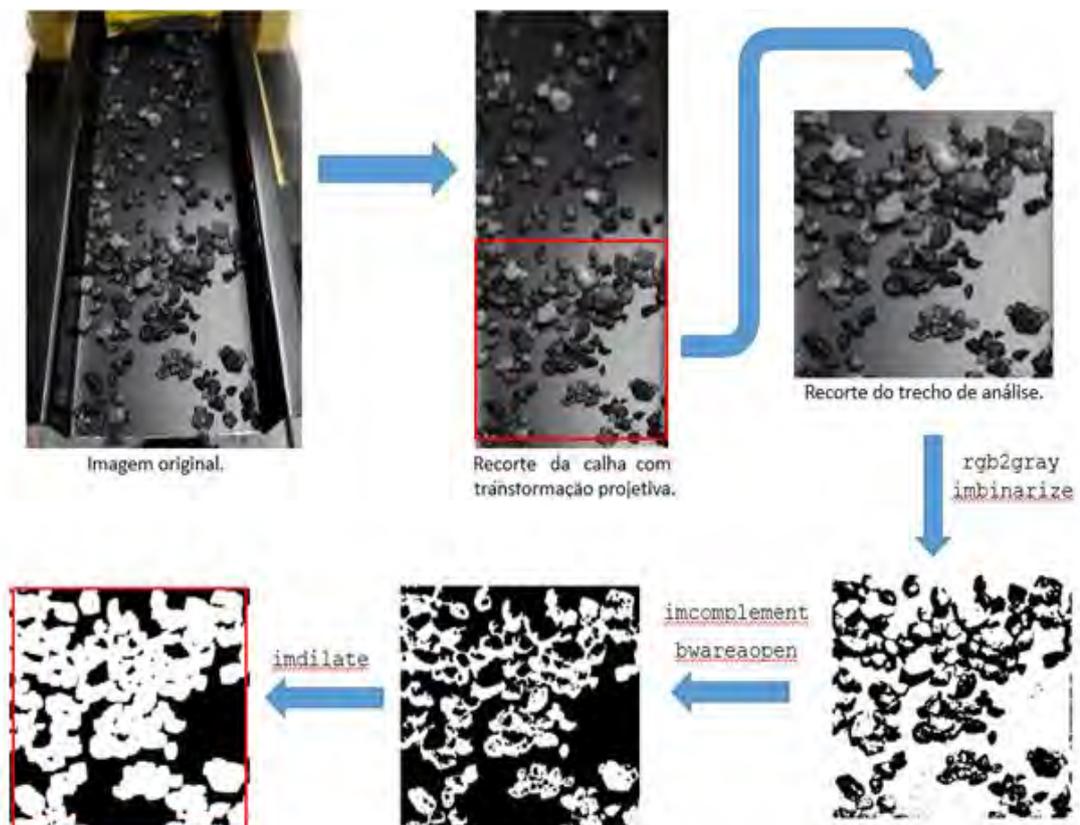


Figura 77. Etapas do processamento de imagens para o grupo II.

Fonte: O autor.

A etapa de pré-processamento envolve uma transformação projetiva, de forma a obter a vista superior do escoamento e dois recortes sucessivos: o primeiro compreende toda a região do escoamento e o segundo, o recorte de análise. Para a segmentação ainda é necessário converter a imagem para tons de cinza, limitação do método adaptativo de Otsu. O método está descrito na fundamentação teórica e para o caso deste grupo, retorna os objetos em preto e o plano de fundo em branco. Como a extração de características é feita para a configuração de objetos brancos e plano de fundo preto, é necessário incluir uma etapa de pós-processamento que envolva a inversão de cores. Em seguida, para a remoção de pequenos ruídos e reconstrução de bordas suprimidas, realiza-se uma operação de dilatação.

A Figura 78 ilustra o resultado da detecção para três exemplos do método descrito, onde os sólidos detectados estão demarcados em vermelho. Abaixo de cada uma das imagens encontra-se o resultado da estimativa %AP calculada para cada caso.

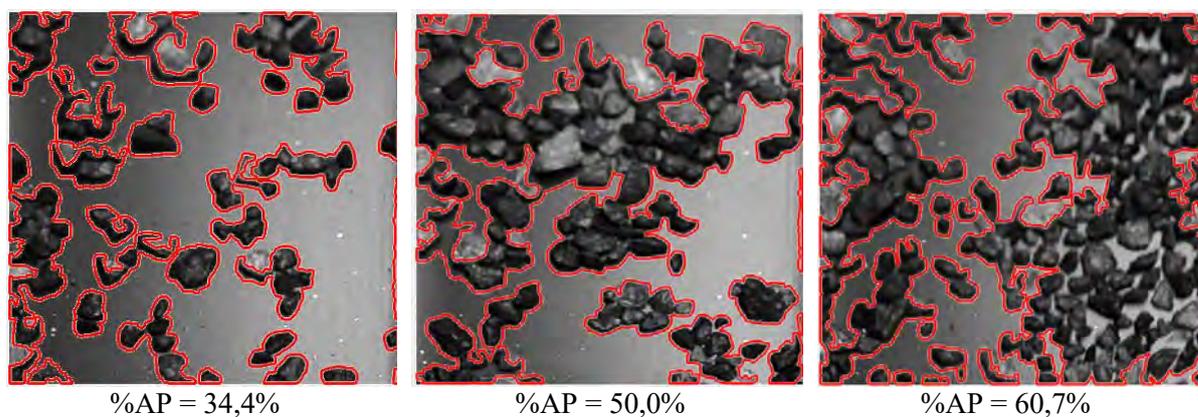


Figura 78. Segmentação. Escoamento de pedras a 40% de vibração.  
Fonte: O autor.

Como as análises deste grupo utilizaram somente um tipo de sólido, a classificação com redes neurais convolucionais não foi aplicada. Outra estimativa não aplicável foi o número de sólidos em escoamento. Assim como no Grupo I, os sólidos também se deslocam em blocos, entretanto, o tamanho das partículas não é regular, dessa forma, a estratégia de utilizar a mediana da área não funcionaria.

A mediana funciona para o Grupo I porque todas as partículas de um mesmo tipo de grão têm aproximadamente o mesmo tamanho. Isso não ocorre para o Grupo II, onde o mesmo tipo de rocha, quartzo, possui três faixas diferentes de tamanho. Além disso, cada tipo de grão do Grupo I tem binarização representada por uma camada da máscara de saída, podendo ter o NGE estimado separadamente. No Grupo II não há separação, a saída é uma imagem única.

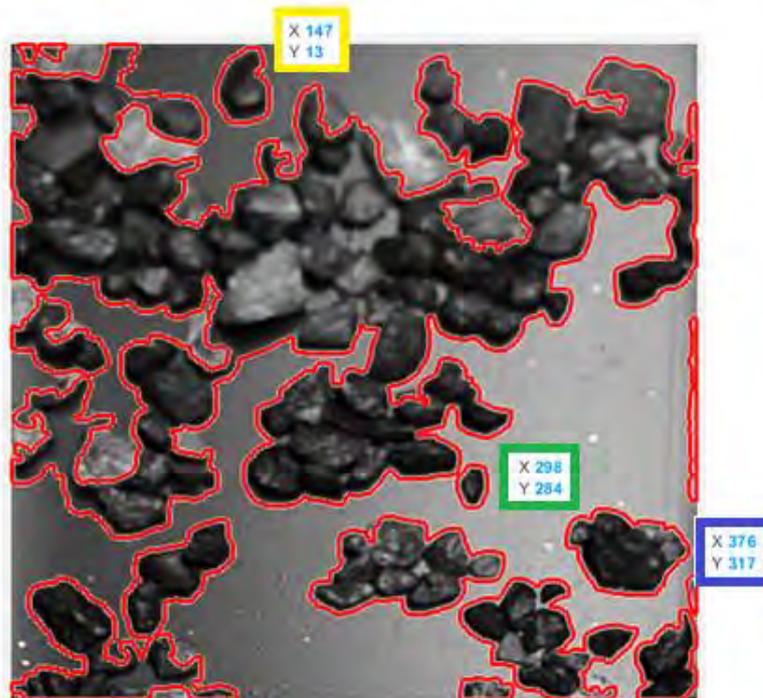
A estimativa de tamanho de partículas compreendeu a medição do maior e menor eixo de cada um dos subgrupos de pedras. Em um primeiro momento, esses sólidos foram identificados na imagem e, com auxílio do descritor ‘caixa delimitadora’, foi possível identificar qual linha da matriz de características representava cada um deles. Os descritores maior e menor eixo foram convertidos para medidas do mundo real a partir da relação entre as medidas da largura da calha: 466 *pixels* equivalem a 12,5cm.

Na Figura 79 é ilustrado um exemplo de detecção dos fragmentos em que é possível identificar um fragmento de cada subgrupo. A caixa delimitadora ao lado de cada um em (A) indica as coordenadas utilizadas para encontrá-los na matriz de características, onde a demarcada em verde indica o subgrupo de menor tamanho, em amarelo, intermediário e azul,

maior tamanho. Em (B) é possível obter os valores dos descritores associados a cada um dos fragmentos.

Na

Tabela 6 é apresentada a comparação dos valores de maior e menor eixo de cada subgrupo estimados por meio do aplicativo com a média dos tamanhos medidos em laboratório.



(A)

	Area	BoundingBox			Circularity	MajorAxisLength	MinorAxisLength	
1	83	448.5000	354.5000	5	23	0.4648	25.3459	4.6133
2	170	6.5000	0.5000	29	11	0.3905	30.1711	10.3750
3	320	449.5000	183.5000	4	119	0.0715	131.3045	3.7418
4	383	298.5000	422.5000	32	14	0.7135	34.6640	14.6849
5	1067	137.5000	4.5000	32	47	0.8369	46.5376	30.6599
6	1545	414.5000	377.5000	39	59	0.5567	58.9079	36.7208
7	2798	368.5000	310.5000	78	54	0.7895	73.3941	50.6171
8	4368	298.5000	356.5000	114	80	0.3091	106.7265	66.2485
9	4600	199.5000	315.5000	125	62	0.4752	114.5951	56.6788
10	7339	0.5000	317.5000	148	119	0.1753	160.2333	102.7033
11	80236	0.5000	0.5000	453	326	0.0828	496.0909	287.4367

(B)

Figura 79. (A) Imagem de referência para identificação dos sólidos medidos; (B) Tabela de características extraídas para todos os objetos identificados.

Fonte: O autor.

Tabela 6. Validação da estimativa de tamanho de fragmento para o grupo II.

Subgrupo	Tamanho Estimado (mm)	Tamanho Real (mm)	
		Maior Eixo	Menor Eixo

	<b>Maior Eixo</b>	<b>Menor Eixo</b>	<b>Média</b>	<b>Desvio Padrão</b>	<b>Média</b>	<b>Desvio Padrão</b>
Pequeno	9,3	3,9	7,3	0,7	5,5	0,9
Médio	12,5	8,2	11,8	1,3	9,1	1,6
Grande	19,7	13,6	17,3	2,3	11,0	1,1

Fonte: O autor.

Os resultados mostram que os tamanhos estimados têm valores dentro, ou pelo menos próximos, da faixa delimitada pelos desvios padrão calculados. O resultado está dentro do esperado, levando em consideração os erros associados ao processamento das imagens, que pode acrescentar mais *pixels* ao reconstruir as bordas da imagem e associados à medição, uma vez que, por serem fragmentos muito irregulares, o maior e menor eixo dependem da sensibilidade visual do operador.

Em outro exemplo, o aplicativo processou imagens retiradas de um vídeo fornecido pela Petrobras da operação de uma peneira real. O resultado da análise desse vídeo, ilustrando a detecção de objetos está ilustrada na Figura 80. Esse resultado é promissor, porque detecta regiões onde o cascalho possivelmente se encontra, mas a técnica de detecção ainda precisa ser melhorada.

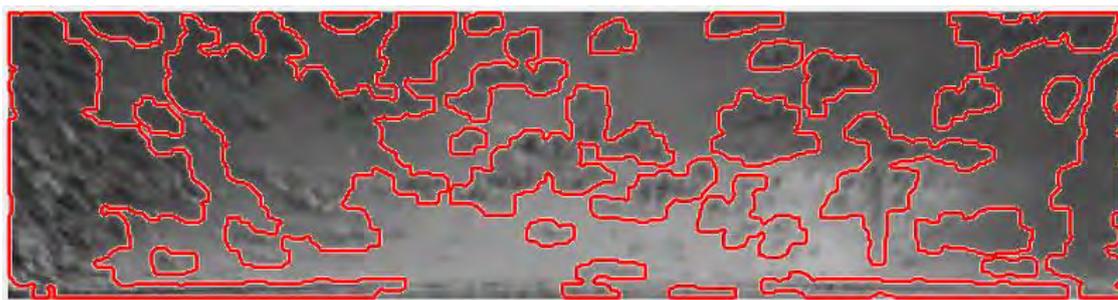


Figura 80. Segmentação de cascalho em escoamento em peneiras vibratórias.

Fonte: O autor.

Um dos fatores que mais dificulta a detecção é a baixa resolução da imagem, onde a ausência de bordas bem definidas e iluminação variável em toda a imagem fazem com que as variações nas intensidades dos *pixels* não sejam percebidas corretamente pelo algoritmo.

### 7.3 Grupo III

Cada um dos materiais desse grupo foi separado por faixas de tamanho e a representação dessa diferença é mostrada na Figura 81. Somente as três maiores faixas foram utilizadas em ensaios na unidade experimental, uma vez que fragmentos muito pequenos de pedras são confundidos com ruídos de calha. Analogamente para o cascalho, frações menores podem não ser detectados, por estarem embebidos em fluido de perfuração e eventualmente passarem pela abertura da tela da peneira.

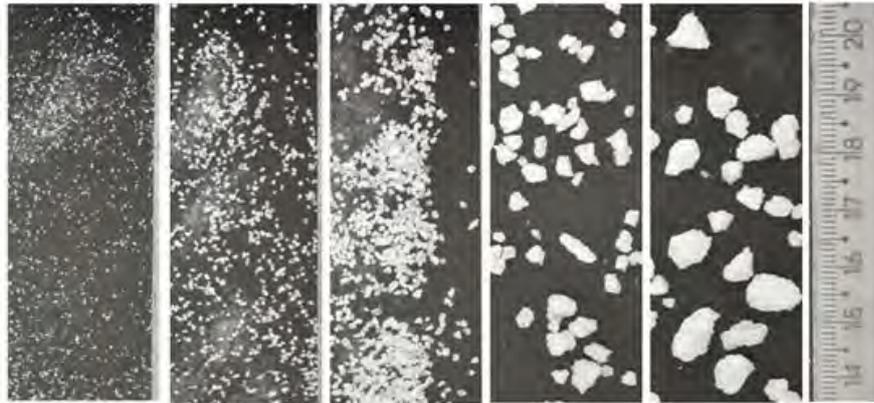


Figura 81. Representação das frações de mármore.  
Fonte: O autor.

O objetivo dos ensaios com esse grupo foi fazer ajustes no processamento de imagens para que o algoritmo fosse capaz de detectar de forma satisfatória todos os quatro tipos de sólidos em todas as faixas de tamanho definidas. Os resultados para a detecção são apresentados nas imagens a seguir, onde na Figura 82 apresenta-se a detecção para cada um dos quatro tipos de sólido e na Figura 83 a detecção para todos os tamanhos.

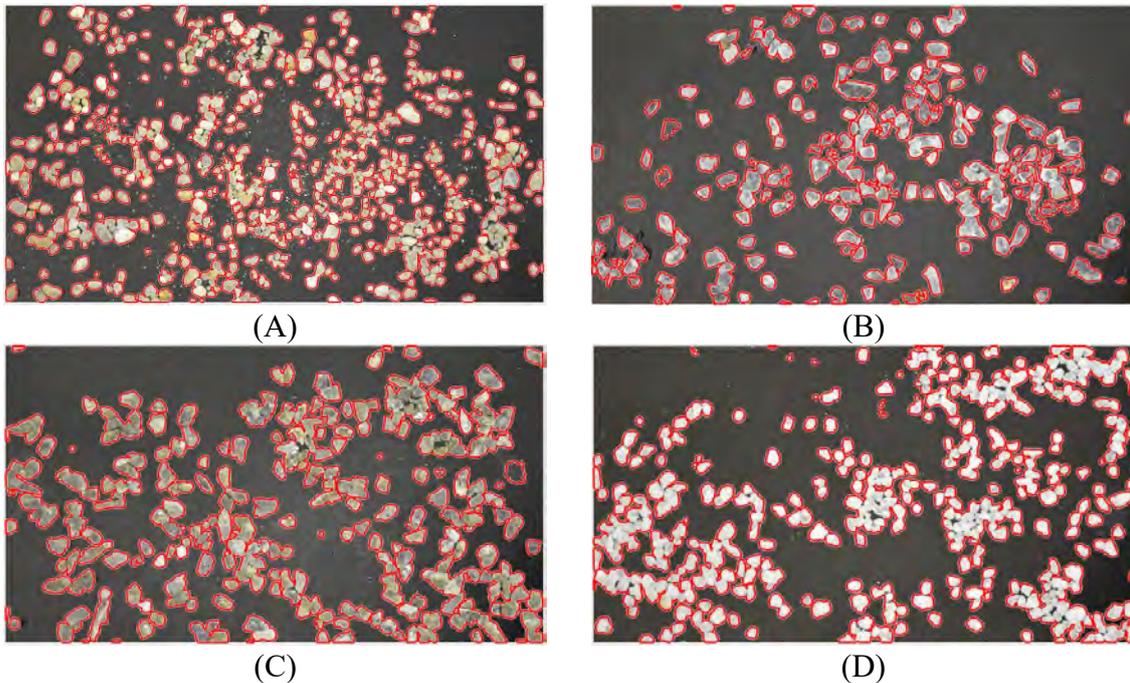


Figura 82. Detecção de fragmentos dos quatro materiais diferentes.  
(A) Areia; (B) quartzo; (C) granito; (D) mármore.  
Fonte: O autor.

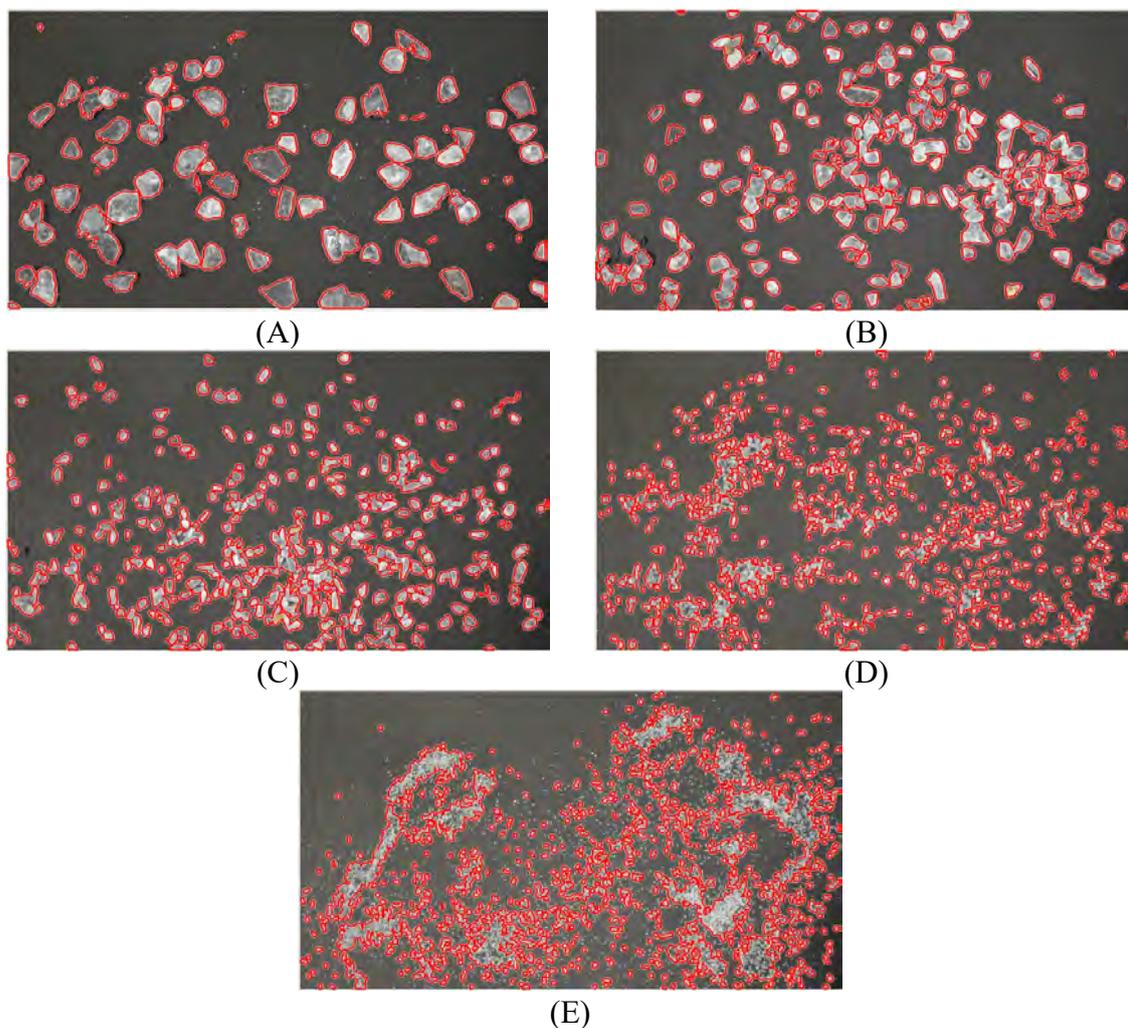


Figura 83. Detecção de fragmentos de granito nos cinco tamanhos propostos pela metodologia. (A) 2,36mm; (B) 1,18mm; (C) 0,60mm; (D) 0,30mm; (E) 0,15mm.

Fonte: O autor.

Os resultados de detecção mostraram bom desempenho para todos os tipos de sólido em tamanhos variados, fazendo deste o melhor método de segmentação encontrado até o momento. O estudo com este grupo seguiu com o desenvolvimento e validação das estimativas de porcentagem da calha preenchida por sólidos e velocidade de escoamento.

### 7.3.1 Porcentagem da calha preenchida por sólidos (%AP)

Para validar a estimativa de %AP foram capturadas cenas em que essa medida fosse conhecida e dessa forma, o erro associado a essa estimativa pôde ser calculada. A seguir são apresentadas imagens ilustrativas de quatro porcentagens e a tabela com o cálculo dos erros.

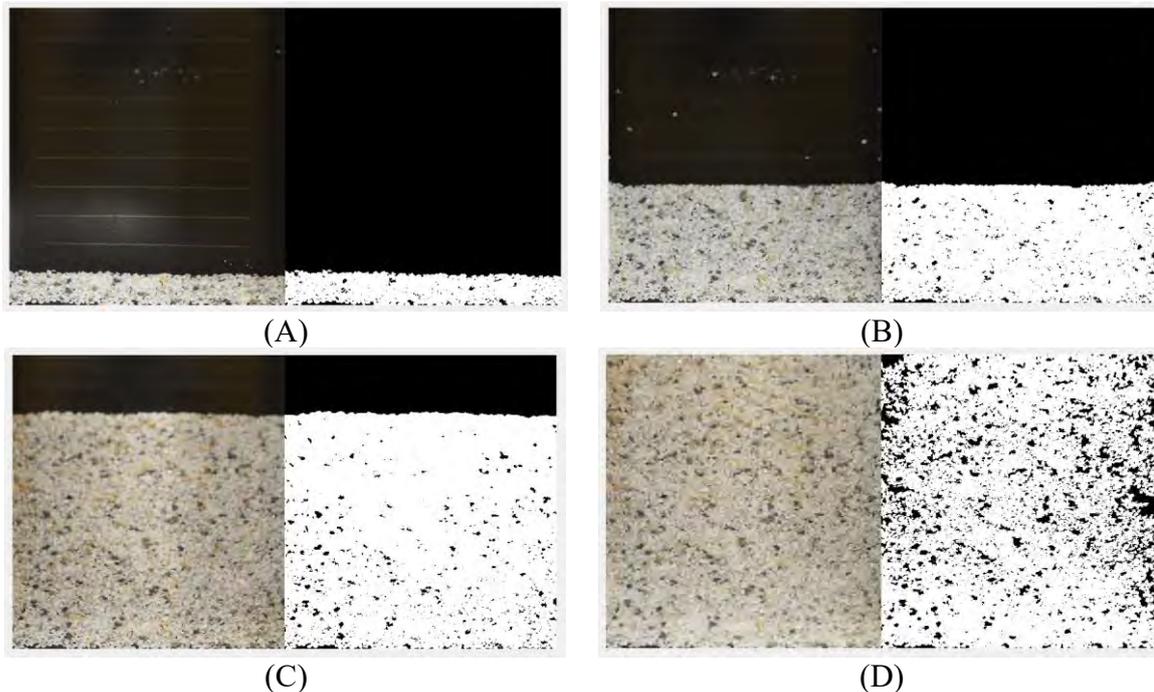


Figura 84. Validação da estimativa %AP. (A) 10%; (B) 40%; (C) 80%; (D) 100%.  
Fonte: O autor.

A partir dos resultados mostrados, pode-se concluir que o aplicativo foi capaz de estimar de forma satisfatória a %AP. O erro menor que 4% associado a essa medida está relacionado à boas técnicas de detecção de objetos.

Tabela 7. Validação da porcentagem da calha preenchida por sólidos (%AP).

%AP Estimada	%AP Real	Erro (%)
<b>10,10</b>	10	1,00
<b>20,60</b>	20	3,00
<b>29,52</b>	30	1,60
<b>39,53</b>	40	1,18
<b>49,82</b>	50	0,36
<b>59,40</b>	60	1,00
<b>68,89</b>	70	1,59
<b>79,66</b>	80	0,43
<b>89,48</b>	90	0,58
<b>96,38</b>	100	3,62

Fonte: O autor.

### 7.3.2 Velocidade de escoamento

Os resultados apresentados a seguir têm como objetivo estimar a velocidade com que os sólidos se deslocam na calha/peneira e validar essas estimativas.

### 7.3.2.1 Um sólido em escoamento

Para validar as estimativas de velocidade foram feitos ensaios, primeiramente, com apenas um único sólido em escoamento, de forma que seu deslocamento pudesse ser monitorado sem interferências. O grão de areia escolhido para essa análise percorreu a calha passando por dez marcações com espaçamento de 2cm e o tempo necessário para que a parte inferior do grão tocasse em cada uma dessas marcações foi registrado.

A velocidade média de escoamento para cada trecho (VMT) foi calculada dividindo os 2cm pelo tempo que o sólido levou para percorrer essa distância. A velocidade média na calha (VMC) foi calculada a partir da média das VMT's. Foram testadas três intensidades de vibração diferentes, valores pré-selecionados de acordo com a velocidade encontrada nos experimentos de validação da unidade experimental, e os resultados são mostrados na Tabela 8.

Tabela 8. Dados experimentais de velocidade para um sólido em escoamento. Fonte: O autor.

25% de Vibração		30% de Vibração		35% de Vibração	
VMT	VMC	VMT	VMC	VMT	VMC
0,37		0,65		1,99	
0,37		0,58		2,12	
0,37		0,79		2,2	
0,38		0,92		2,34	
0,38	0,41	1	0,97	2,14	2,47
0,35		1,01		2,38	
0,42		1,07		2,66	
0,44		1,23		3,21	
0,46		1,2		3,01	
0,53		1,29		2,64	

A velocidade estimada (VE) pelo aplicativo foi calculada para cada um dos *frames* registrados nos vídeos. Para isso, dividiu-se a distância percorrida entre dois *frames* sequenciais, calculada por seis métodos diferentes, pelo tempo 1/30 s. Foram obtidos 1.482 pontos para 25% de vibração, 651 para 30% e 246 para 35%.

Para que os valores de VE fossem comparados com VMT, identificou-se o *frame* inicial e final correspondente ao escoamento em cada um dos trechos e calculou-se a média das velocidades estimadas nesse intervalo, como mostra a Equação 36.

$$v_{estimada/trecho} = \frac{\sum v_{estimada}}{n_{frames}} \quad \text{Equação 36}$$

Cada um dos métodos para o cálculo da distância utilizou um detector diferente: MSER, Harris, SURF, FAST, BRISK e ORB. Dentre eles, apenas o primeiro foi capaz de estimar a VMT de forma satisfatória e isso pode ser explicado pela forma com que seu algoritmo detecta o objeto em movimento.

Na Figura 85 é ilustrada a diferença no tipo de detecção utilizando como exemplo o detector de Harris, que avalia pontos de interesse (mais precisamente as quinas das imagens) e o detector MSER, que avalia regiões de estabilidade, demarcando o deslocamento de um centro de massa. Ambos os métodos estão descritos no Apêndice 1.

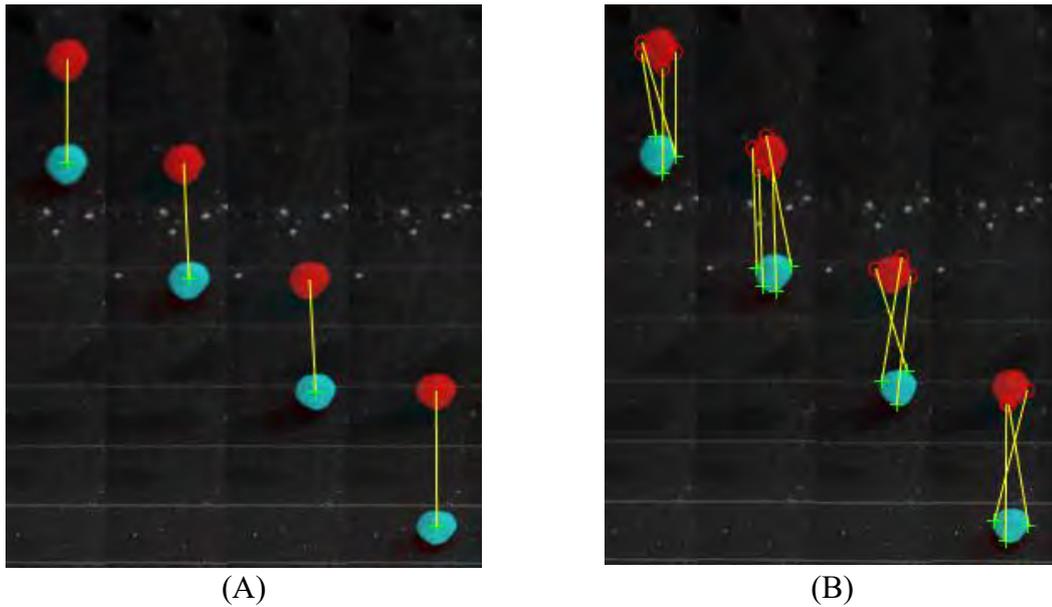


Figura 85. Correspondência entre frames para os detectores (A) MSER e (B) Harris.

Fonte: O autor.

A seguir são mostrados os gráficos do comportamento de cada um desses detectores para as três intensidades de vibração ensaiadas. A curva correspondente a VMT representa a velocidade real e as outras, nomeadas como 'VE + método' representam a velocidade estimada por cada um dos descritores.

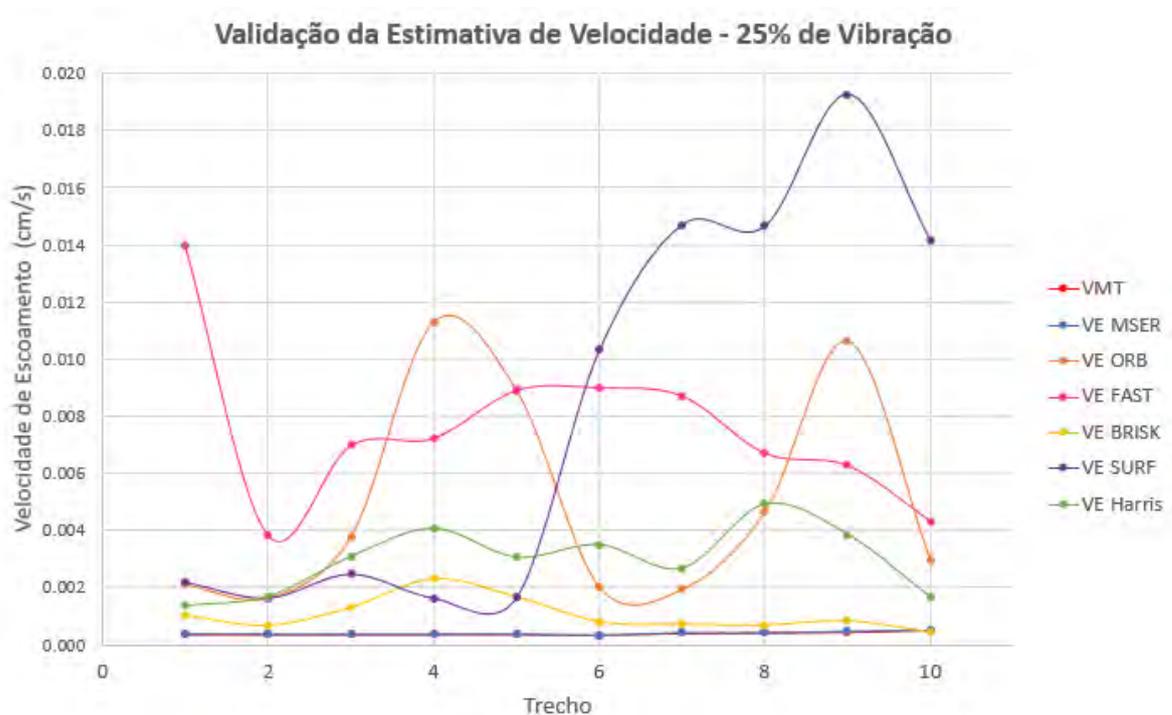


Figura 86. Validação da estimativa de velocidade para 25% de intensidade de vibração.

Fonte: O autor.

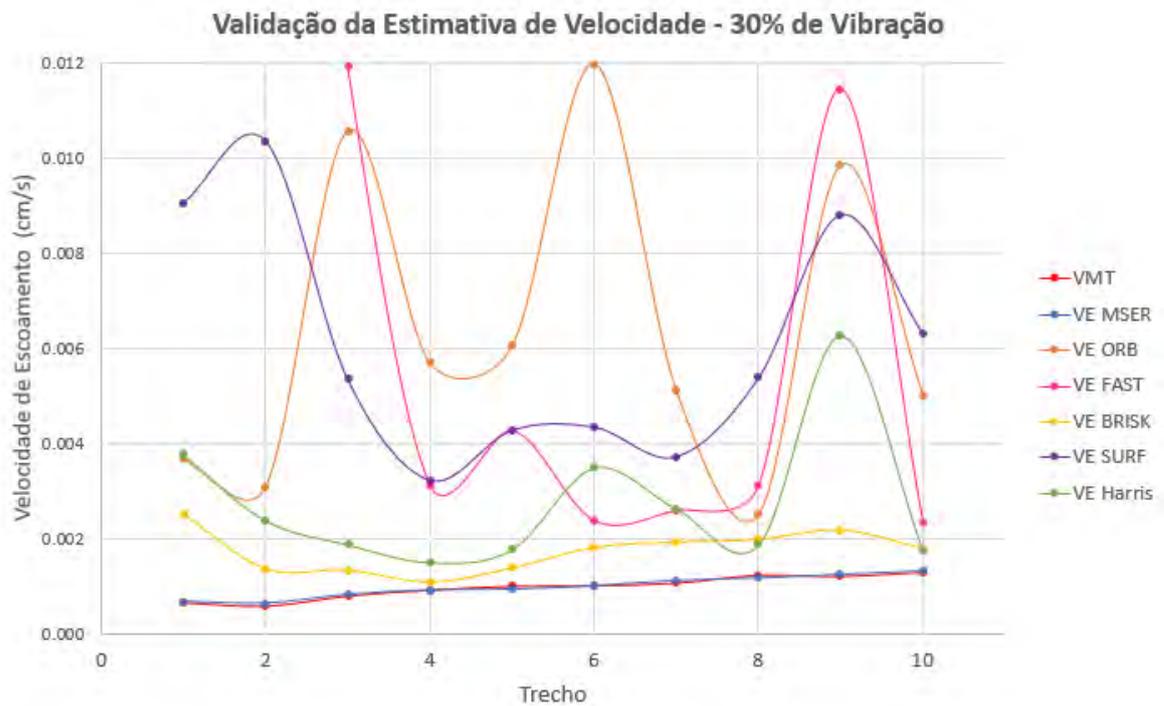


Figura 87. Validação da estimativa de velocidade para 30% de intensidade de vibração.  
 Fonte: O autor.

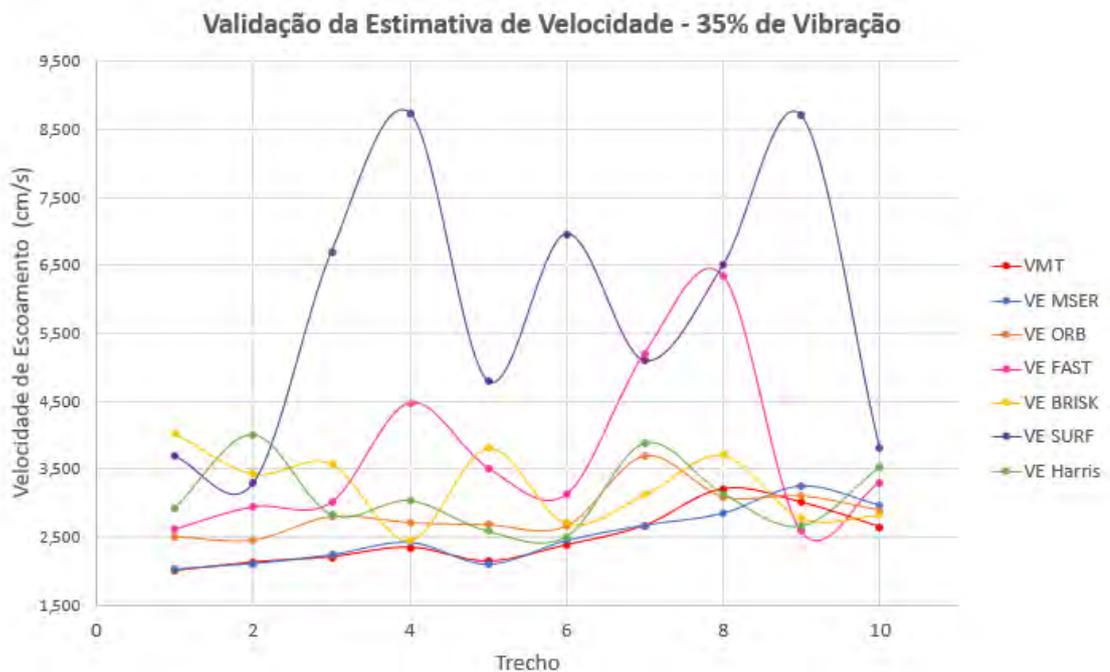


Figura 88. Validação da estimativa de velocidade para 35% de intensidade de vibração.  
 Fonte: O autor.

Como mencionado anteriormente e observado nos gráficos acima, o detector de melhor desempenho para um único objeto em escoamento foi o MSER, que descreveu de forma satisfatória o comportamento da velocidade ao longo da calha. Dessa forma, pode-se observar na Figura 89 e na Tabela 9 os valores obtidos para este detector.

As VMT's, em verde, representam as velocidades medidas a cada trecho e VE's, em vermelho, as velocidades médias estimadas para o trecho correspondente.

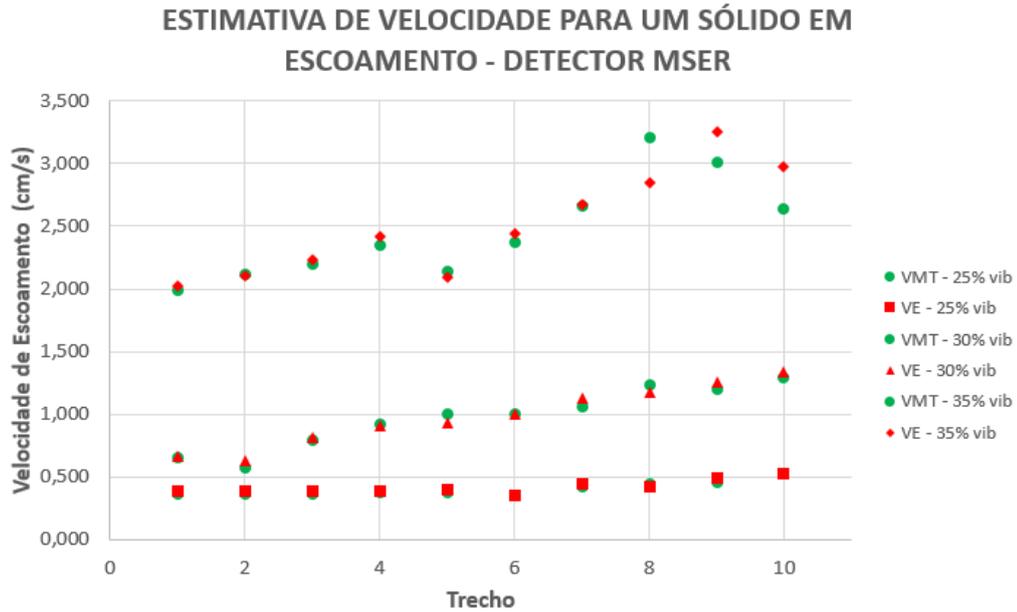


Figura 89. Desempenho do detector MSER para um sólido em escoamento.  
Fonte: O autor.

Tabela 9. Validação da estimativa de velocidade para um sólido em escoamento.

Intensidade de Vibração	Velocidade por Trecho – cm/s			Velocidade Média na Calha – cm/s		
	Estimada	Medida	Desvio (%)	Estimada	Medida	Desvio (%)
25%	0,39	0,37	6,33	0,42	0,41	1,54
	0,39	0,37	5,11			
	0,38	0,37	3,13			
	0,38	0,38	0,75			
	0,39	0,38	4,57			
	0,35	0,36	0,86			
	0,44	0,43	3,71			
	0,42	0,46	8,55			
	0,50	0,45	9,29			
	0,52	0,55	3,77			
30%	0,67	0,65	2,50	0,99	0,99	0,24
	0,63	0,58	7,38			
	0,82	0,80	2,28			
	0,91	0,94	2,51			
	0,93	1,00	6,69			
	1,01	1,02	0,98			
	1,13	1,09	3,27			
	1,18	1,28	7,75			
35%	1,26	1,20	4,90	2,50	2,51	0,20
	1,34	1,33	0,23			

2,10	2,14	<b>1,94</b>
2,23	2,22	<b>0,34</b>
2,42	2,40	<b>0,68</b>
2,09	2,14	<b>2,40</b>
2,44	2,40	<b>1,71</b>
2,67	2,73	<b>2,03</b>
2,85	3,33	<b>14,60</b>
3,25	3,00	<b>8,47</b>
2,97	2,73	<b>8,97</b>

Fonte: O autor.

Como observado na determinação da VMT, a velocidade não se mantém constante ao longo da calha e o algoritmo foi capaz de detectar e medir de forma satisfatória essas variações com um erro menor que 10% considerando cada trecho e menor que 2% para velocidade média na calha. Vale destacar que o escoamento dessa partícula não foi regular, apresentando leve deslocamento diagonal e rotacional possivelmente associados à vibração e ao atrito em superfície irregular, entretanto as medidas e estimativas são obtidas apenas do escoamento vertical em relação à aquisição da imagem, ou seja, da saída do silo para o final da calha, considerando aquisição dos vídeos a partir da vista superior.

### 7.3.2.2 Vários sólidos em escoamento – Estudo da Calha Inteira

Nas peneiras reais ocorre escoamento de vários sólidos simultaneamente, dessa forma, é necessário validar o algoritmo desenvolvido anteriormente para esta situação.

Para a validação da velocidade fez-se uma análise preliminar considerando os mesmos 20cm avaliados no código anterior e todos os seis detectores foram testados. Diferente do primeiro caso, dois detectores apresentaram resultados coerentes: MSER e Harris e seus métodos estão descritos no Apêndice 1.

Ao longo do escoamento é possível observar a formação de grandes blocos de sólidos, bem como a desfragmentação deles em blocos menores. Isso dificulta a detecção pelo método MSER, entretanto, o detector alcançou desempenho satisfatório pelo fato de vários blocos serem identificados a cada *frame* e, dessa forma, caso um deles não seja detectado no *frame* seguinte, a estimativa de velocidade ainda pode ser dada por todos os outros.

Como há muitos sólidos com características semelhantes, é possível que haja mais de uma combinação de intensidades para *pixel* central e vizinhanças, que caracterizam as quinas, o que leva o método de Harris à detecção de ruídos que precisaram ser eliminados.

Na Figura 90 é ilustrado em (A) dois tipos diferentes de ruído: o primeiro considerado ruído de fundo, onde uma imperfeição na calha é detectada em posições diferentes devido à vibração. Esses ruídos levam a distâncias calculadas muito pequenas e são mostrados com os marcadores cruz e círculo sobrepostos. O segundo é devido a correspondência incorreta de objetos diferentes, mas considerados iguais pela combinação das intensidades dos *pixels*, que se repetem. Esse tipo de ruído leva a estimativa de distância muito maior do que a esperada e com grande deslocamento diagonal.

Para remoção desses ruídos foi necessário impor restrições de deslocamento nas direções  $x$  e  $y$  e o resultado típico obtido após a remoção é mostrado em (B). O deslocamento considerado para o cálculo da velocidade é vertical, sendo assim, uma variação significativa na coordenada  $x$  indica equivalência incorreta de objetos. Como a velocidade varia pouco ao longo da calha e se mantém praticamente constante nos mesmos trechos de escoamento, foram selecionados

valores máximos de  $y$  que o deslocamento poderia assumir de acordo com a intensidade de vibração ensaiada.

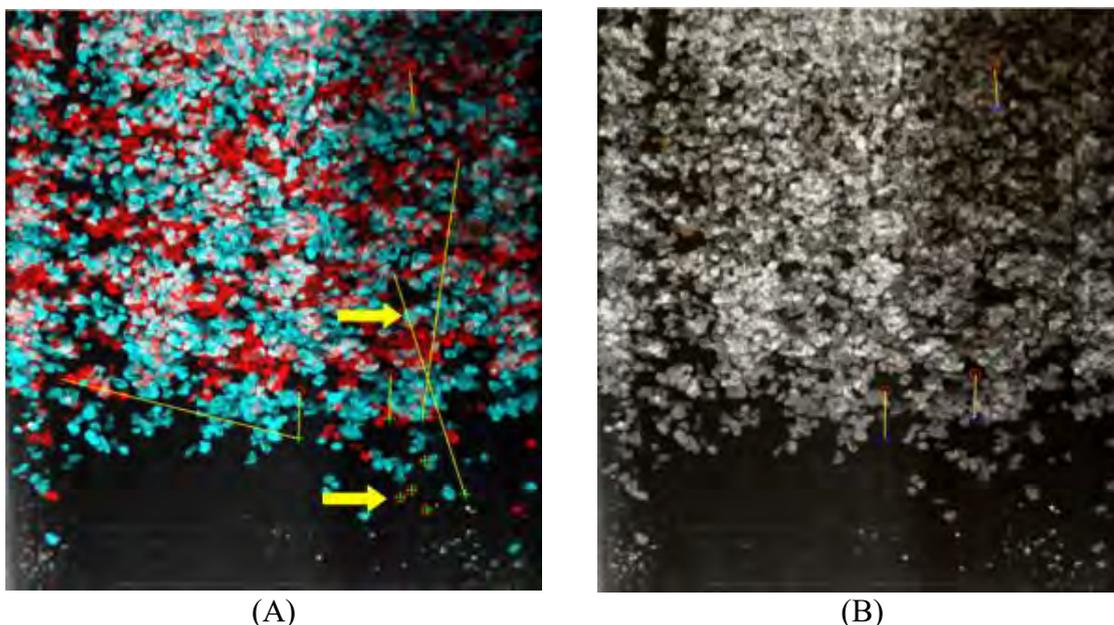


Figura 90. Eliminação de ruídos no algoritmo para cálculo de velocidade na calha inteira: (A) imagem com todos os pontos detectados pelo algoritmo; (B) imagem sem ruídos.

Fonte: O autor.

Depois dos ajustes no algoritmo, foi feita a validação somente para os fragmentos quartzo, granito e mármore, uma vez que a areia, mesmo após separação granulométrica, não manteve suas características de tamanho e forma durante o escoamento, ou seja, esfarelou-se. Isso pode ter ocorrido por utilizar areia não padronizada, onde aglomerados de grãos não foram desfeitos no peneiramento realizado no pré-tratamento, desfazendo-se pela vibração da calha.

Na Tabela 10 são apresentados os resultados obtidos para as três intensidades de vibração. A velocidade real (coluna 3) representa a velocidade média medida durante o escoamento e a velocidade média estimada (coluna 4) representa a média de todas as velocidades estimadas durante o escoamento. Os resultados apresentados são relativos ao método MSER, que apresentou desempenho semelhante ao método de Harris, mas com a vantagem de ser mais rápido, uma vez que detecta menos pontos e conseqüentemente, menos ruído.

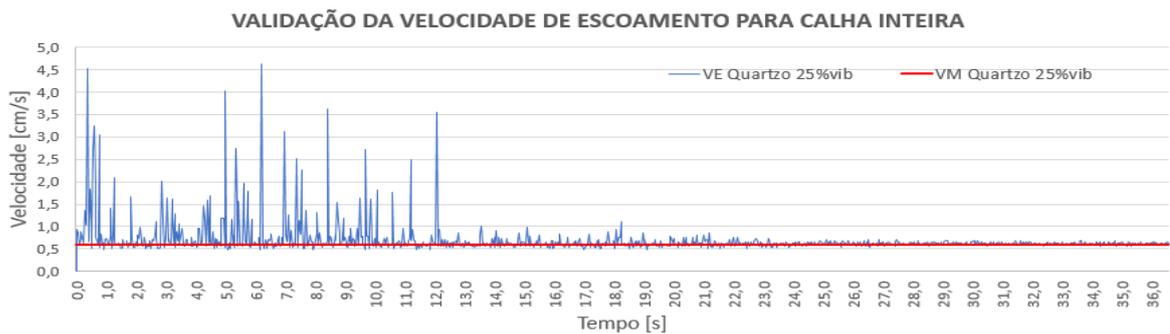
Tabela 10. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira.

Tipo de Fragmento	Intensidade de Vibração	Velocidade Real [cm/s]	Velocidade Média Estimada [cm/s]	Desvio [%]
Quartzo	0,25	0,590	0,621	5,2
	0,3	1,628	1,595	2,1
	0,35	3,197	3,109	2,8
Granito	0,25	0,580	0,643	10,7
	0,3	1,643	1,580	3,9
	0,35	3,185	3,165	0,6
Mármore	0,25	0,473	0,625	32,2

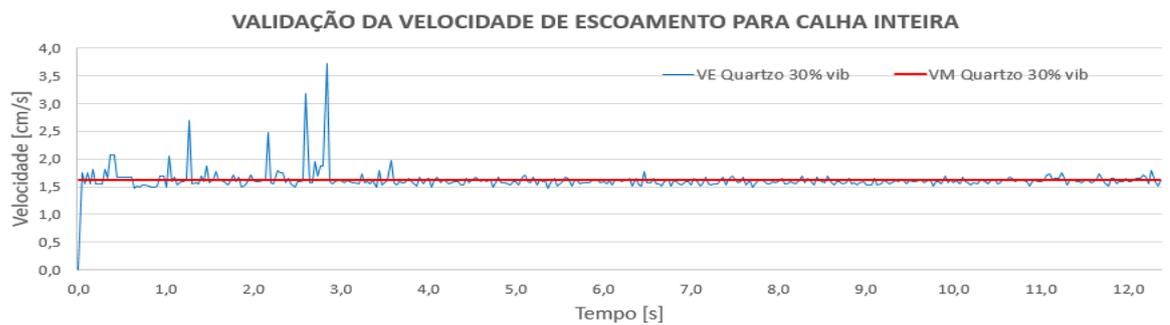
0,3	1,595	1,576	1,2
0,35	3,032	3,183	5,0

Fonte: O autor.

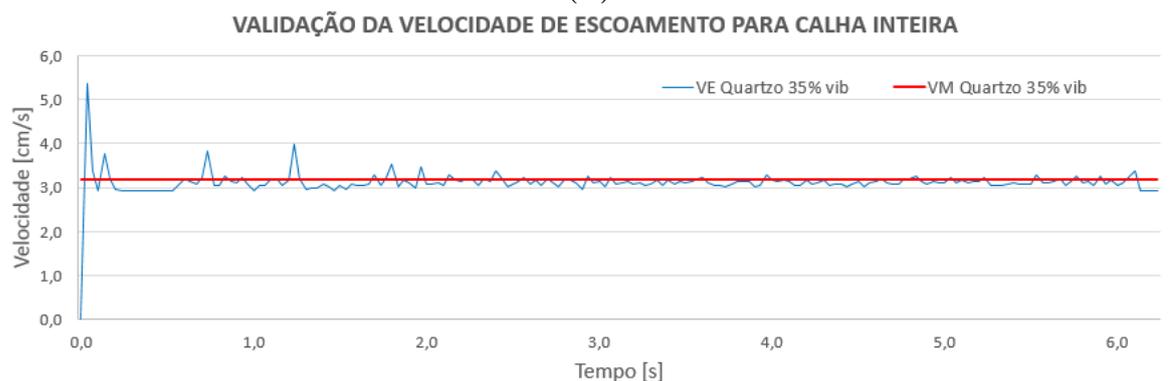
Avaliando os desvios obtidos, observa-se que foram quase sempre inferiores a 10%, o que mostra que o algoritmo estimou a velocidade para vários sólidos em escoamento de forma satisfatória. Os comportamentos observados ao longo do tempo são mostrados graficamente nas figuras a seguir, que comparam a velocidade média medida, em vermelho, com a velocidade estimada, em azul, para os três sólidos nas três intensidades de vibração.



(A)



(B)



(C)

Figura 91. Validação da estimativa de velocidade para o quartzo.

Fonte: O autor.

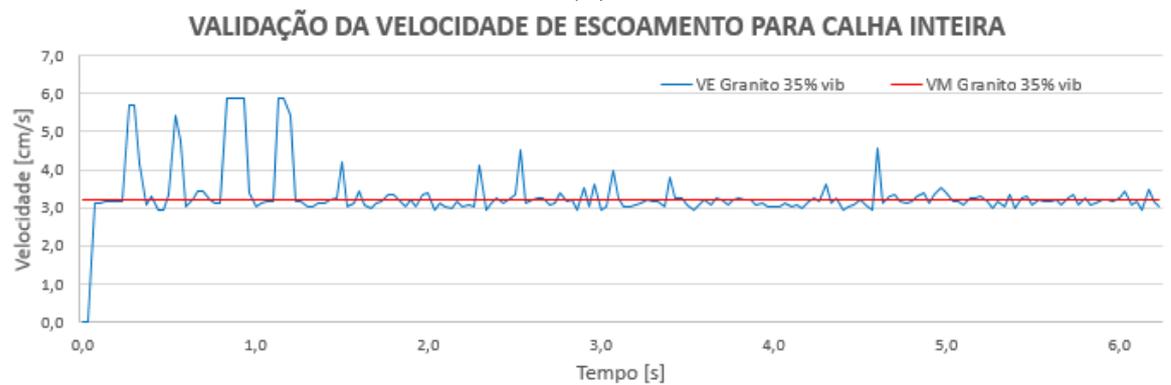
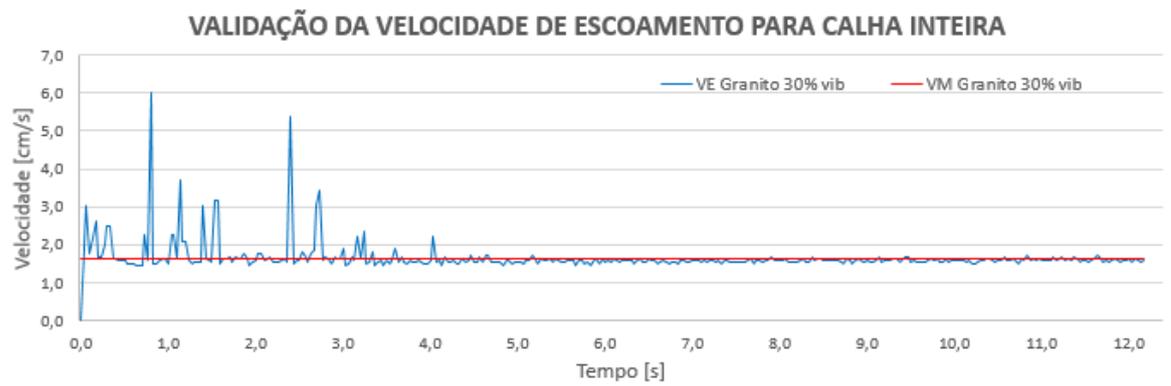
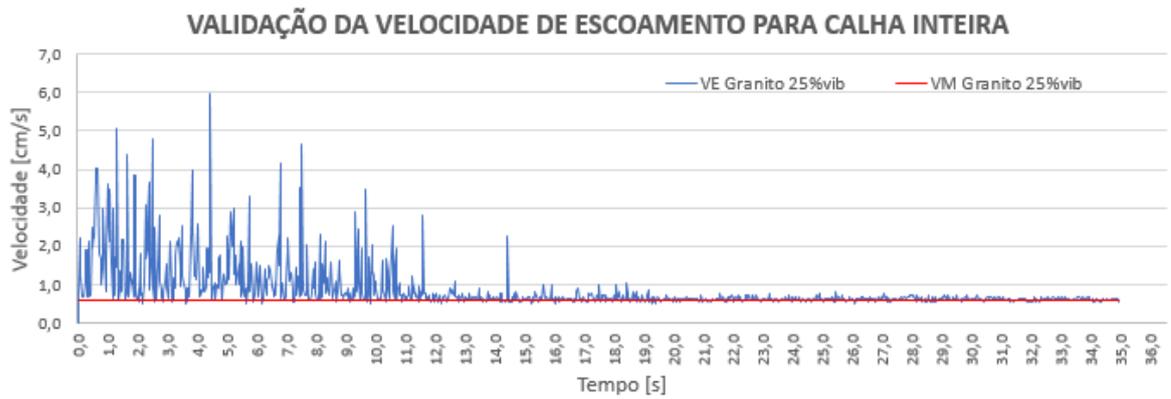
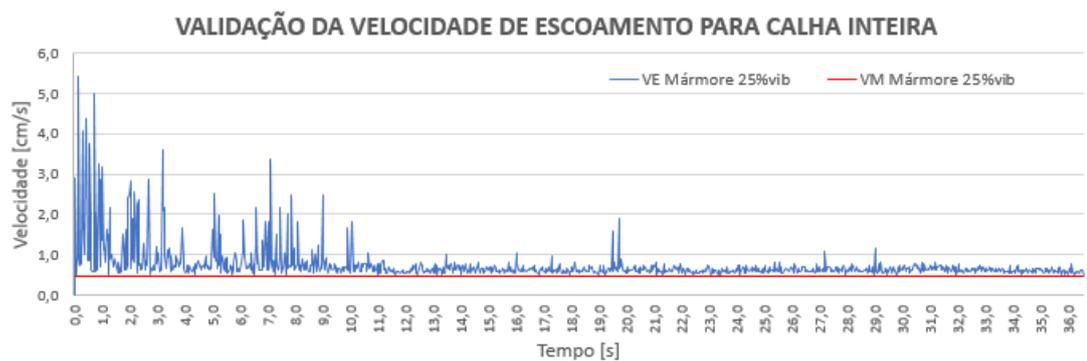
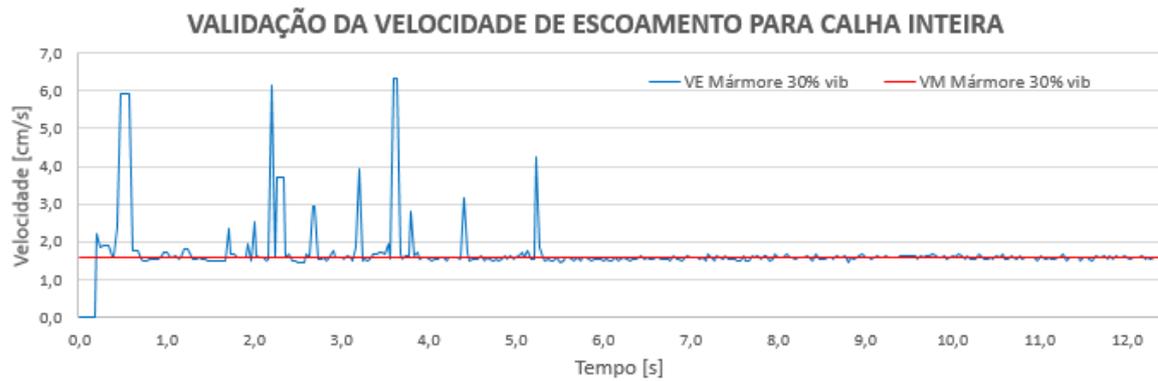
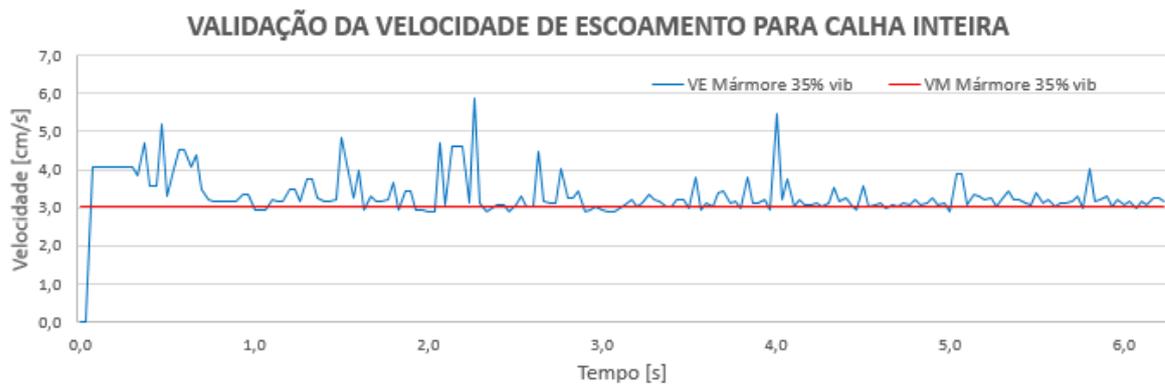


Figura 92. Validação da estimativa de velocidade para o granito.  
Fonte: O autor.





(B)



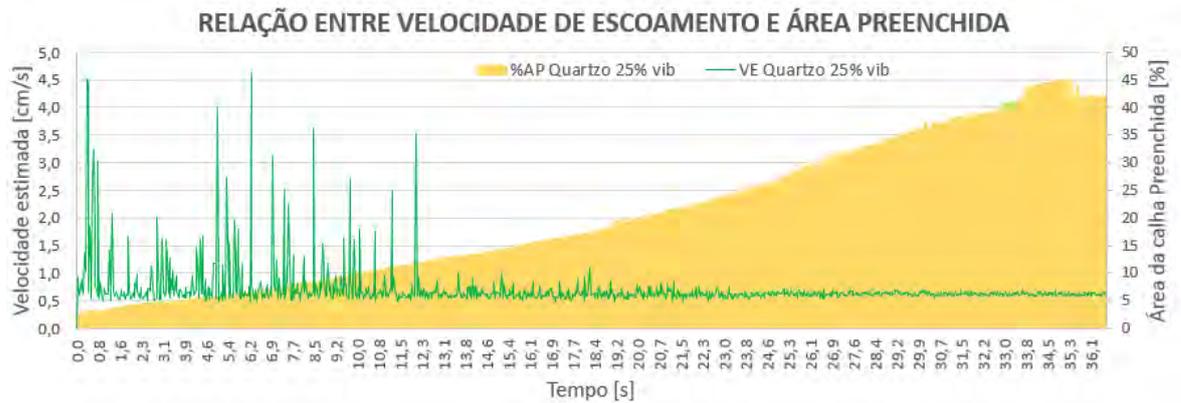
(C)

Figura 93. Validação da estimativa de velocidade para o mármore.  
Fonte: O autor.

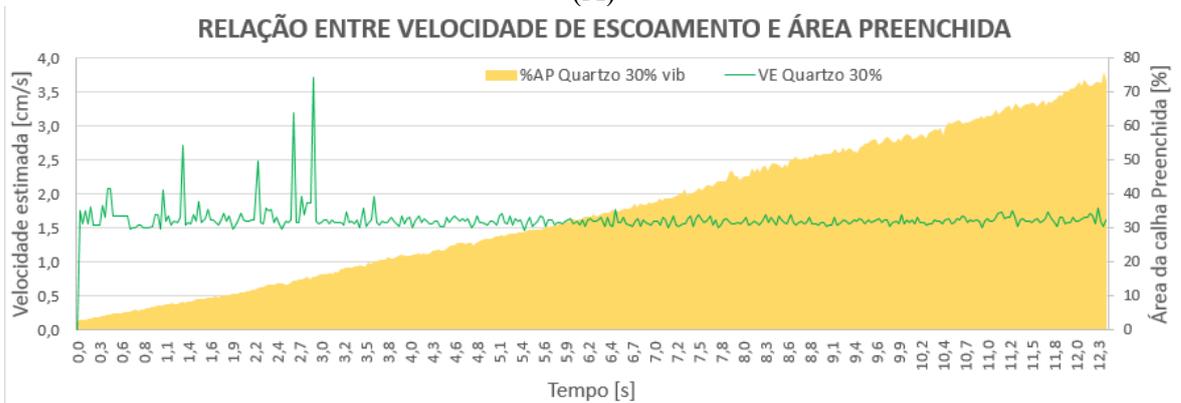
Avaliando os resultados gráficos, observa-se que no início do escoamento as medições oscilam muito, mas depois entram em regime permanente. Isso pode ser explicado pela porcentagem de sólidos presentes na calha. Ao comparar as duas variáveis estimadas, velocidade e %AP, para um mesmo instante de tempo, é possível observar que o regime permanente é encontrado quando a %AP é maior do que 15% e isso acontece para todos os casos.

Essa limitação do aplicativo pode ocorrer pela dificuldade de encontrar pontos válidos para o cálculo de distância quando a calha está com baixo preenchimento, levando em consideração que o ensaio é iniciado com a calha vazia, que vai sendo preenchida. Tal fato leva a detecção de muitos ruídos oriundos de vibrações e variações na iluminação. A variação na iluminação ocorre porque esta variável não foi controlada, e os ensaios foram realizados em dias e horários diferentes, estando sujeitos a iluminação natural no galpão do LEF/UFRRJ.

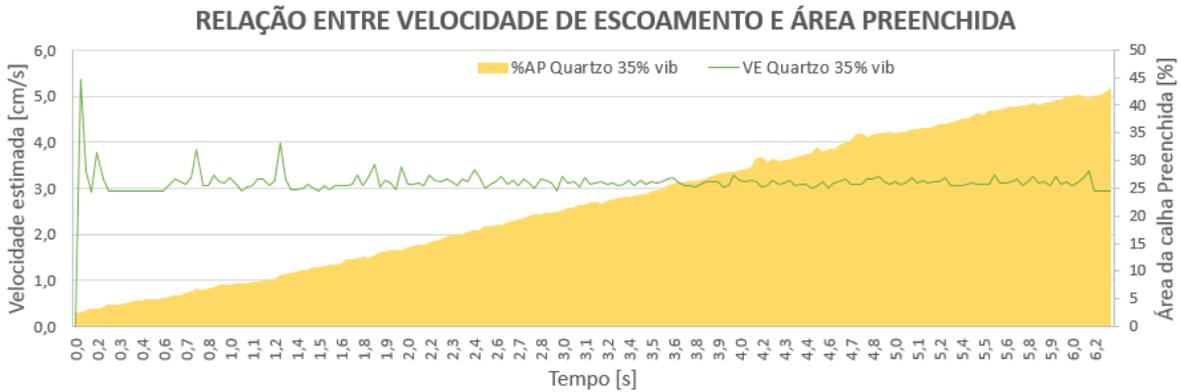
Na Figura 94 é ilustrada graficamente essa comparação para o quartzo, onde a linha verde representa a velocidade e a região amarela representa a %AP. Vale ressaltar que esse comportamento também foi observado para os outros dois sólidos.



(A)



(B)



(C)

Figura 94. Relação entre as variáveis VE e %AP para o quartzo nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%.

Fonte: O autor.

Pelos resultados apresentados, pode-se dizer que o aplicativo de visão computacional foi adequadamente ajustado e está apto a realizar estimativas de velocidade para vários sólidos em escoamento. Entretanto, ainda possui uma limitação em relação à quantidade mínima de sólidos presentes na calha. O trecho estudado é grande em relação ao tamanho de partículas, então, uma estratégia para minimizar a limitação é reduzir o recorte de análise. Além disso, a intenção do estudo foi monitorar a saída da peneira, o que tornou necessária a adaptação do código para um trecho bem reduzido.

### 7.3.2.3 Vários Sólidos – Final da Calha

Como já foi comprovado que a velocidade varia de acordo com a posição na calha, as simulações foram refeitas considerando-somente o último trecho da calha, com 2cm de comprimento. A remoção de ruídos com imposição de restrição em  $x$  e  $y$  foi mantida e forneceu bons resultados, como mostrado na Figura 95.

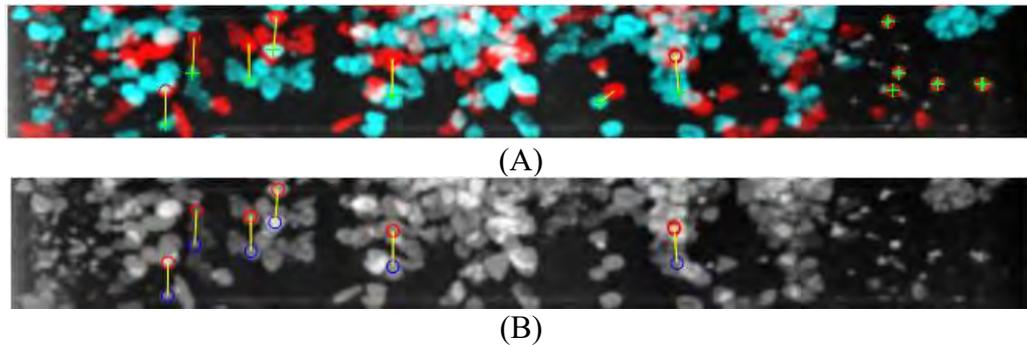


Figura 95. Eliminação de ruídos no algoritmo para cálculo de velocidade no último trecho da calha: (A) imagem com todos os pontos detectados pelo algoritmo; (B) imagem sem ruídos.

Fonte: O autor.

O conjunto de imagens para essa análise é diferente, já que a área do recorte de análise é reduzida e, conseqüentemente, menos objetos serão avaliados em um único frame. Dessa forma, todos os detectores foram reavaliados e três apresentaram resultados coerentes: MSER, SURF e Harris.

O gráfico apresentado na Figura 96 mostra um exemplo da resposta dos três detectores para um mesmo experimento. Nessa figura, o gráfico em (A) corresponde a um ensaio de quartzo a 35% de vibração e em (B), a aproximação de uma parte do gráfico. A linha vermelha representa a velocidade real medida experimentalmente e as curvas em azul, verde e laranja representam, respectivamente, a resposta dos detectores MSER, SURF e Harris.

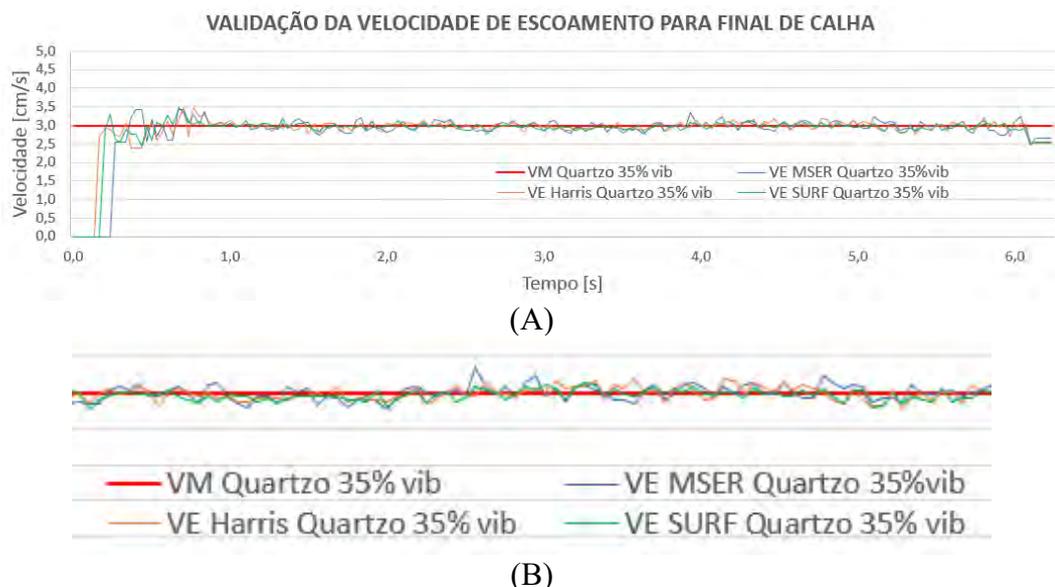


Figura 96. Comparação as velocidades de escoamento do quartzo a 35% de vibração estimada por três detectores diferentes.

Fonte: O autor.

Como pode ser observado graficamente e mostrado na Tabela 11 a seguir, apesar de pontualmente calcularem valores diferentes, pode-se dizer que os três descritores obtiveram resultados similares ao estimar a velocidade, uma vez que suas médias e desvios padrão são bem próximos. Esse comportamento se repetiu para todos os ensaios de final de calha e, por isso, para que a leitura desse trabalho não se torne cansativa, os resultados serão ilustrados para apenas um detector: MSER. A escolha, além de permitir comparação com os outros resultados anteriores, também foi a mais rápida, por detectar menor número de correspondências a cada frame.

Tabela 11. Respostas médias dos descritores MSER, Harris e SURF para um escoamento de quartzo a 35% de vibração.

<b>Detector</b>	<b>Velocidade Real [cm/s]</b>	<b>Velocidade Média Estimada [cm/s]</b>	<b>Desvio Padrão [cm/s]</b>
MSER		2,969	0,141
Harris	3,000	2,964	0,137
SURF		2,942	0,115

Fonte: O autor.

Na Tabela 12 são apresentados os resultados obtidos com o detector MSER para os três sólidos estudados, nas três intensidades de vibração. A velocidade real (coluna 3) representa a velocidade média medida durante o escoamento e a velocidade média estimada (coluna 4) representa a média de todas as velocidades estimadas durante o escoamento.

Tabela 12. Validação da velocidade para vários sólidos utilizando um trecho da calha.

<b>Tipo de Fragmento</b>	<b>Intensidade de Vibração</b>	<b>Velocidade Real [cm/s]</b>	<b>Velocidade Média Estimada [cm/s]</b>	<b>Desvio [%]</b>
<b>Quartzo</b>	0,25	0,47	0,56	18,8
	0,3	1,46	1,41	3,1
	0,35	3,00	2,96	1,4
<b>Granito</b>	0,25	0,51	0,54	6,5
	0,3	1,50	1,43	4,5
	0,35	2,73	2,72	0,3
<b>Mármore</b>	0,25	0,47	0,51	8,2
	0,3	1,40	1,34	4,0
	0,35	2,86	2,62	8,5

Fonte: O autor.

Avaliando os desvios obtidos é possível dizer que o algoritmo também foi capaz de estimar a velocidade de forma satisfatória para um trecho bem menor da calha. Os comportamentos ao longo do tempo são mostrados nas figuras a seguir, que comparam a velocidade média medida, em vermelho, com a velocidade estimada, em azul.

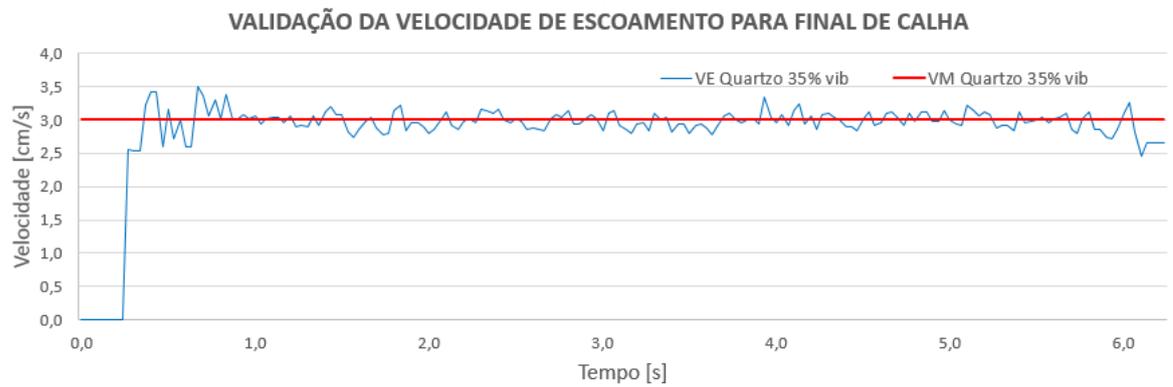
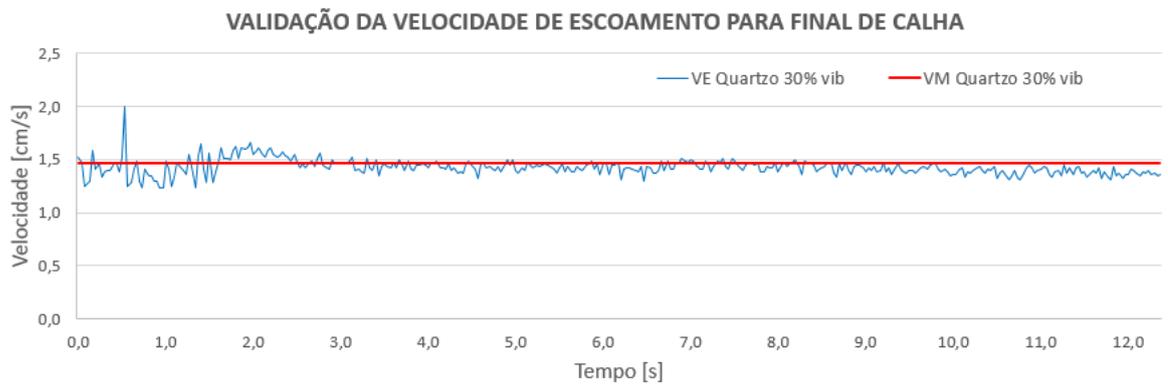
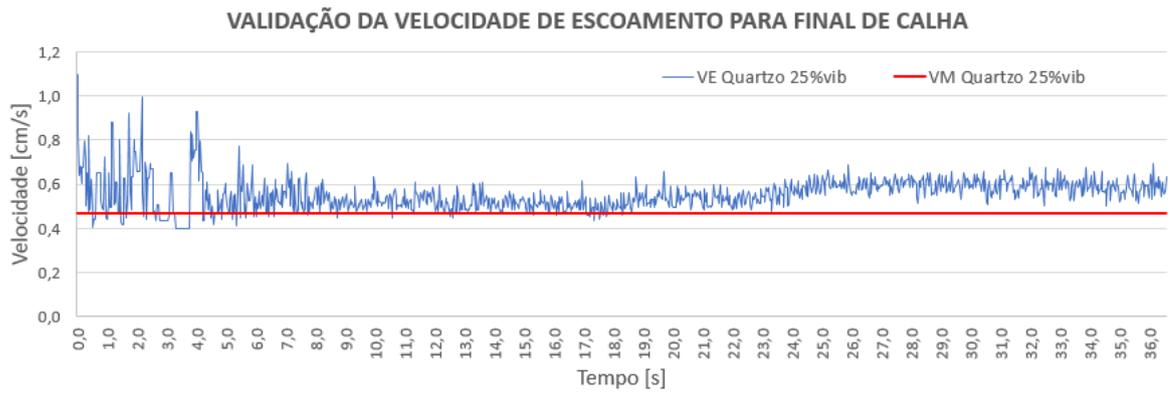
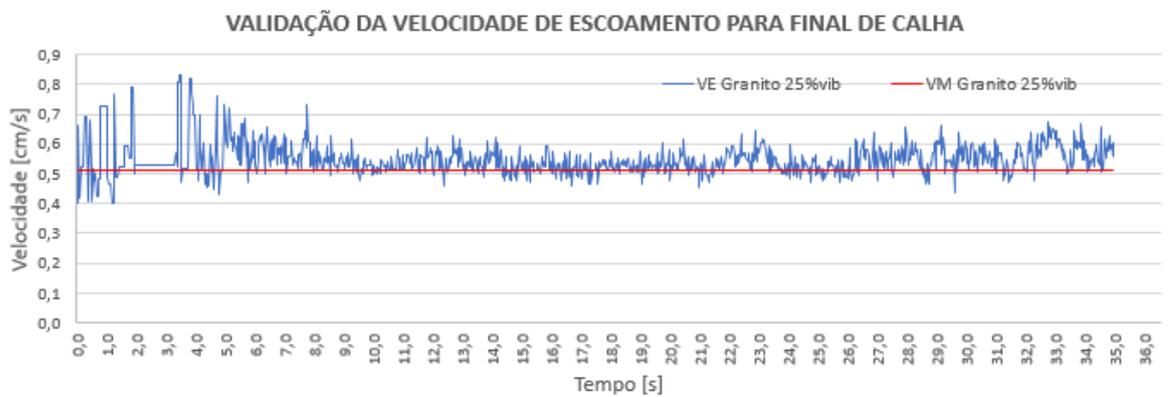


Figura 97. Validação da estimativa de velocidade para o quartzo. Fonte: O autor.



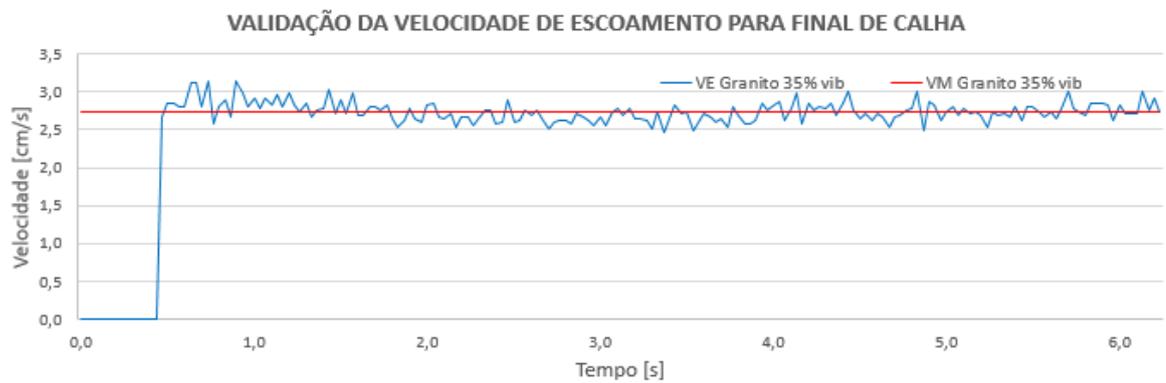
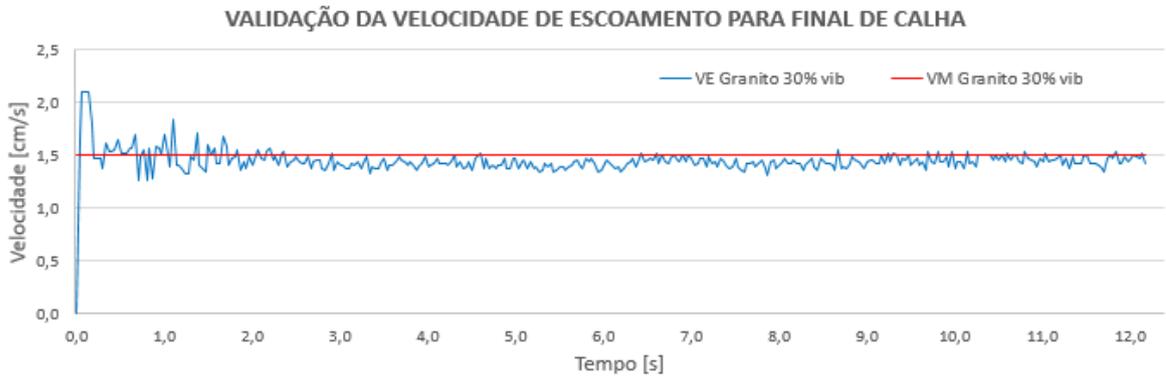
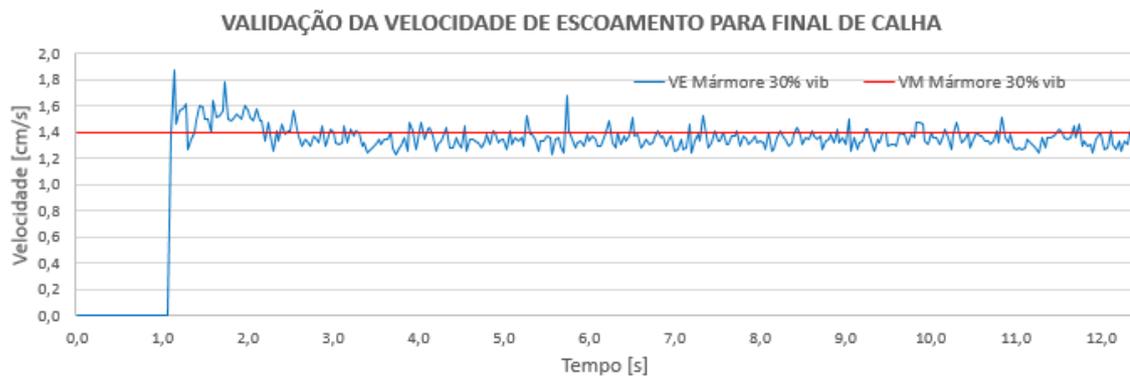
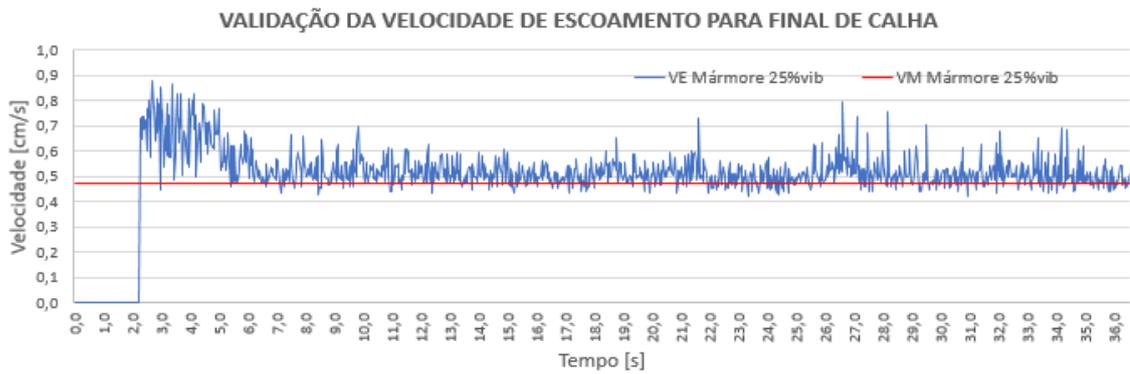
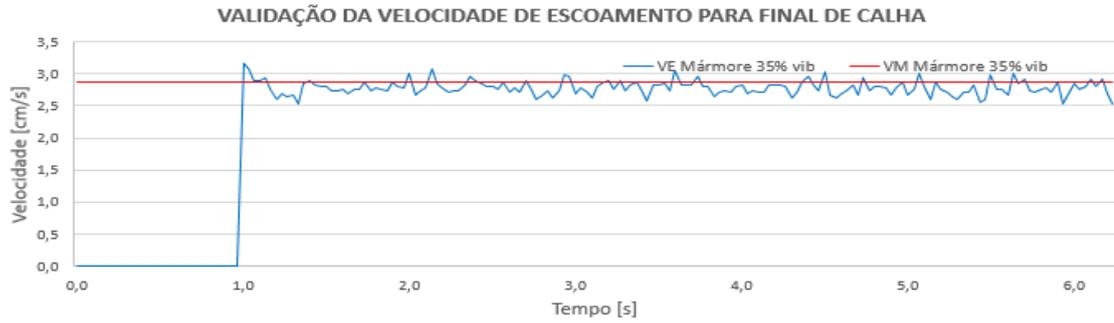


Figura 98. Validação da estimativa de velocidade para o granito. Fonte: O autor.

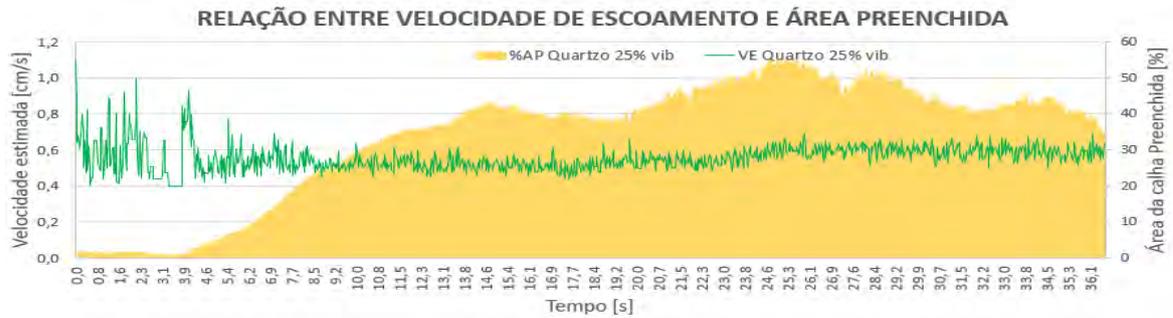




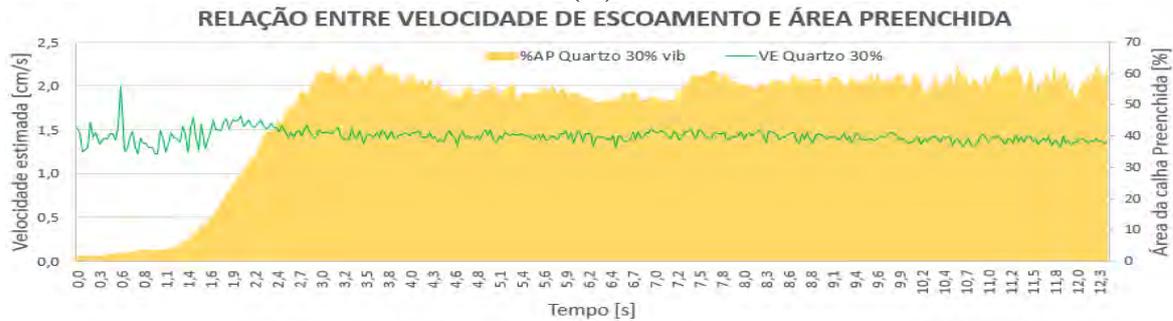
(C)

Figura 99. Validação da estimativa de velocidade para o mármore. Fonte: O autor.

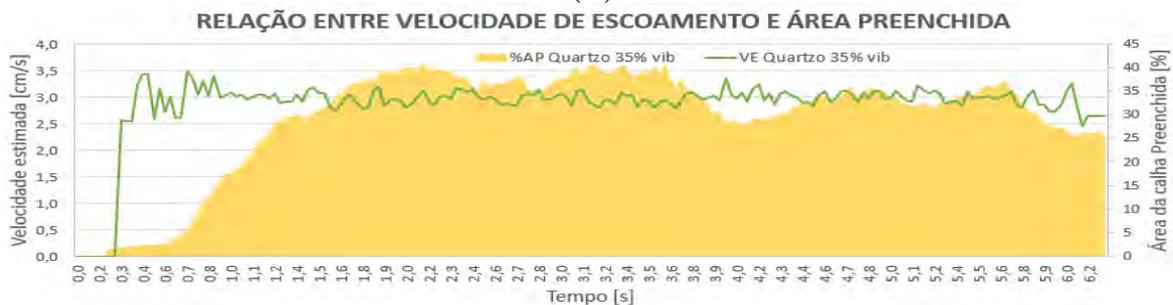
Assim como ocorreu na análise de calha inteira, o escoamento se apresentou inicialmente ruidoso e entrou em regime permanente a partir de um determinado valor de área preenchida. A diferença é que, como o recorte de análise é menor, são necessários menos fragmentos para preencher a %AP mínima que leva o algoritmo a realizar estimativas satisfatórias, o que se mostra visualmente com uma faixa inicial ruidosa bem menor.



(A)



(B)



(C)

Figura 100. Relação entre as variáveis VE e %AP para o quartzo nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%. Fonte: O autor.

Uma observação importante em relação a área é que, para as análises de calha inteira, o ensaio foi realizado inicialmente com a calha vazia, que foi sendo preenchida, portanto, o valor da %AP se apresentou crescente. Para essa nova formatação, o algoritmo “enxerga” não somente o pequeno trecho ser preenchido, mas a continuidade do escoamento. Isso justifica o fato de as áreas não possuírem o mesmo comportamento que nos outros ensaios de calha inteira.

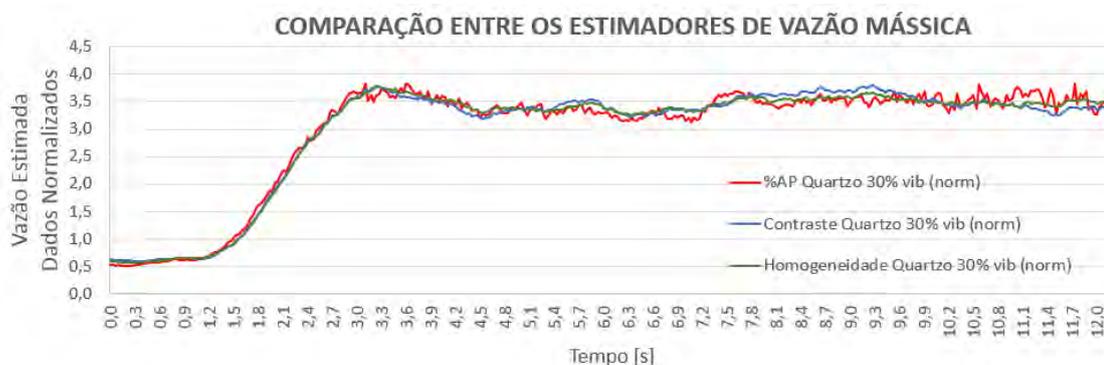
Um aspecto importante a ser mencionado é que, para o caso da calha inteira, alguns vazios comuns ao escoamento caótico não tinham grande influência no valor da %AP total, o que não acontece para um pequeno trecho de calha. Os vazios, anteriormente quase imperceptíveis graficamente, agora podem ocupar uma grande porcentagem do trecho de análise, já que o valor de referência (tamanho do trecho) diminuiu e seu tamanho se manteve o mesmo. Isso pode causar as oscilações apresentadas, por exemplo, na Figura 100A e até quedas bruscas na %AP, levando a medições incorretas.

### 7.3.3 Estimativa da vazão mássica

A estimativa de vazão mássica é de grande interesse para o monitoramento do processo de perfuração, tendo em vista uma possível correlação entre essa variável e a identificação precoce de instabilidades na perfuração do poço. Essa variável pode ser obtida quantitativamente através da aferição da massa de sólidos que sai da peneira a cada unidade de tempo, ou da multiplicação entre a velocidade de escoamento, a densidade do material e a área da seção transversal analisada. Ambas as técnicas são de difícil implementação nas sondas, dessa forma, propõe-se um método baseado em análise de textura que possa fornecer informações qualitativas a respeito do comportamento da vazão.

Neste trabalho foram testados cinco descritores texturais de segunda ordem de Haralick: homogeneidade, contraste, entropia, energia e correlação. As informações necessárias para sua implementação encontram-se na fundamentação teórica do Apêndice 1. Para avaliar a resposta dos descritores utilizou-se a variável já validada %AP, mas apenas os dois primeiros descritores apresentaram resultados compatíveis com os valores de %AP estimados.

A seguir, na Figura 101, são mostrados gráficos que relacionam os descritores qualitativos de vazão para o escoamento de quartzo a 30% de vibração, com recorte de análise abrangendo o final da calha. Em (A) tem-se as três variáveis na forma normalizada, plotadas para o mesmo eixo. Os demais gráficos apresentam os valores reais obtidos, com %AP, em vermelho, com a escala no eixo principal e, (B) contraste e (C) homogeneidade, com as escalas no eixo secundário, em azul e verde, respectivamente. Vale ressaltar que o comportamento se repete para todos os demais sólidos e intensidades.



(A)



(B)



(C)

Figura 101. Relação entre vazão mássica e os descritores (A) contraste, (B) %AP e (C) homogeneidade, para um escoamento de quartzo a 30% de vibração em calha inteira.

Fonte: O autor.

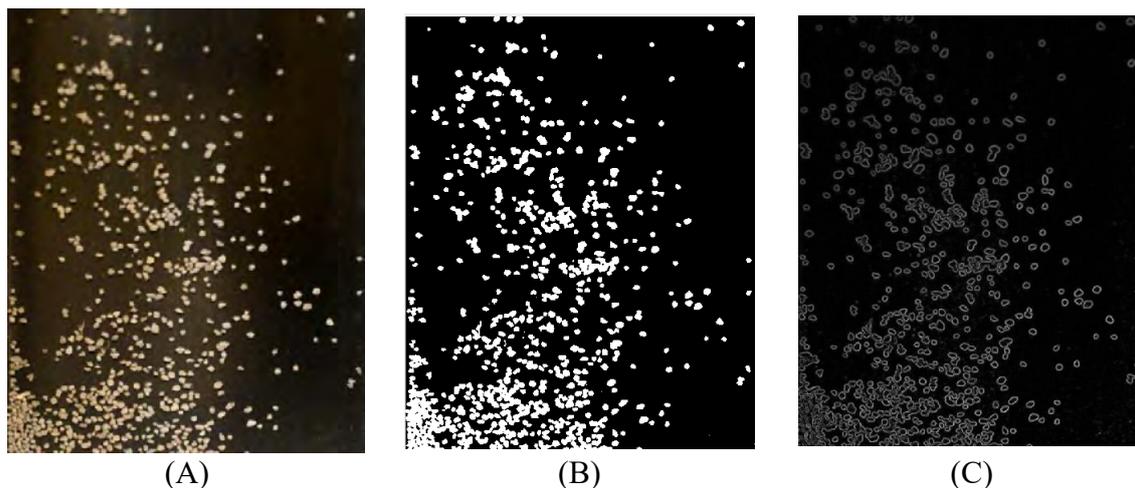
## 7.4 Grupo IV

Os ensaios realizados com esse grupo tiveram como objetivo ajustar o algoritmo para as particularidades do material de interesse deste estudo: cascalhos de perfuração obtidos em poços de petróleo. Primeiro serão mostrados os resultados para o aplicativo de monitoramento do escoamento e, na sequência, os resultados relativos ao aplicativo de apoio ao geólogo.

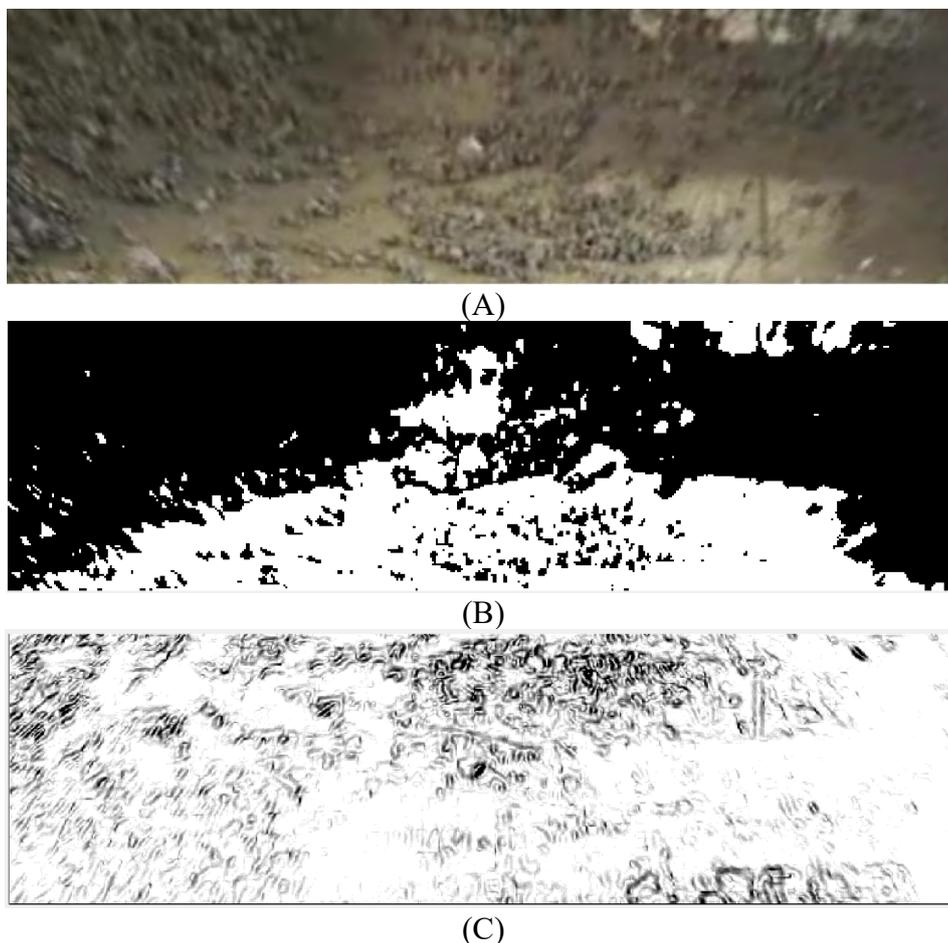
### 7.4.1 Detecção - monitoramento

O primeiro ajuste feito nesse algoritmo foi em relação à etapa de segmentação. Para os ensaios de escoamento do cascalho, de coloração acinzentada em calha tingida de preto, a detecção foi realizada sem muita dificuldade pelo algoritmo *k-means*. Apesar disso, optou-se pela busca de outro algoritmo que fosse eficiente tanto para as simulações de cascalho em laboratório quanto para a detecção em ambiente real de peneiras e, por essa razão, optou-se por utilizar a transformada bidimensional discreta de Fourier em conjunto com o teorema da convolução. O método aplicado está detalhado na fundamentação teórica do Apêndice 1.

Na Figura 102 é ilustrado o resultado da detecção do cascalho ensaiado em laboratório e na Figura 103, a detecção do cascalho em peneira real, em ambas as figuras são apresentados os resultados obtidos com os dois métodos citados.



(A) (B) (C)  
 Figura 102. Identificação de cascalho ensaiado em laboratório: (A) imagem pré-processada; (B) segmentação pelo algoritmo *k-means*; (C) segmentação pela DTF-2D.  
 Fonte: O autor.



(A) (B) (C)  
 Figura 103. Identificação de cascalho em peneiras reais: (A) imagem pré-processada; (B) segmentação pelo algoritmo *k-means*; (C) segmentação pela DTF-2D.  
 Fonte: O autor.

De acordo com os resultados apresentados, o algoritmo que utiliza a DFT-2D em conjunto com o Teorema da Convolução para a detecção de bordas apresentou bom desempenho para

detecção do cascalho nas simulações e o melhor desempenho em situação real, o que fez desta técnica a escolhida para a etapa de segmentação do aplicativo.

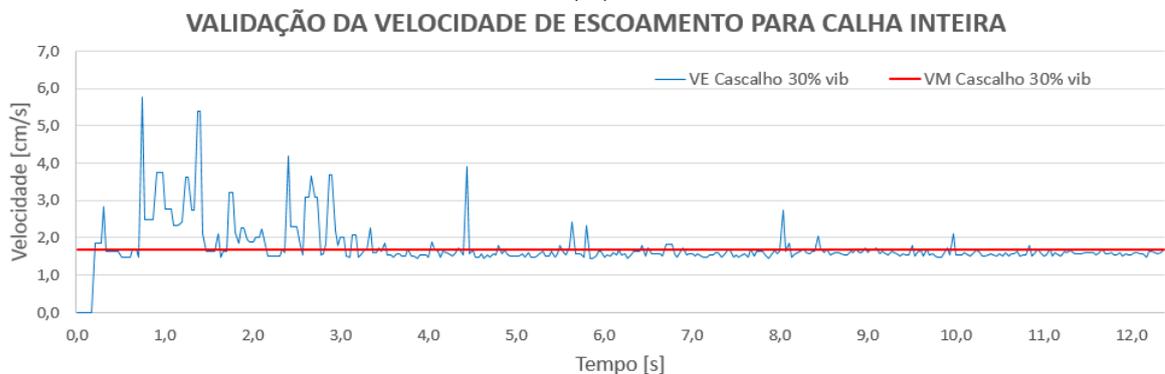
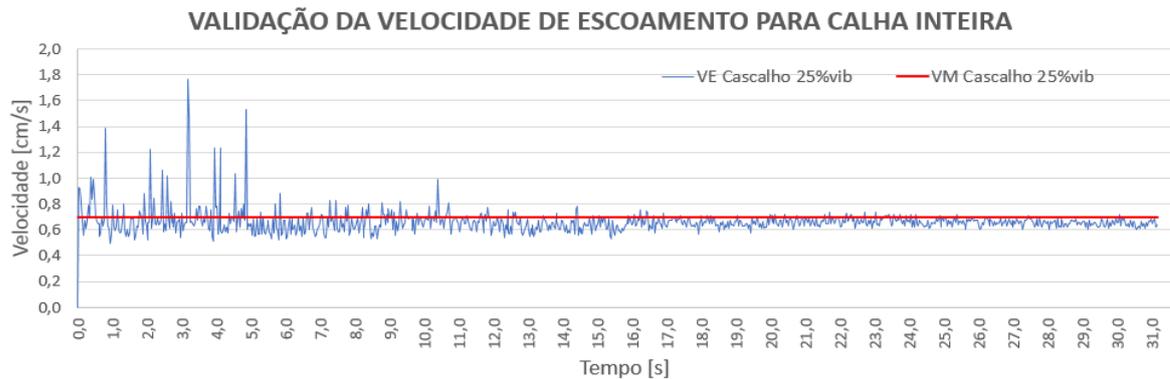
#### 7.4.2 Estimativa da velocidade de escoamento – Calha Inteira

O algoritmo utilizado para o Grupo IV foi o mesmo utilizado para o Grupo III. Na Tabela 13 são apresentados os resultados encontrados para velocidade média de escoamento, estimada e real, considerando a calha inteira. O desvio foi considerado aceitável, por ser menor que 10%. Na Figura 104 são mostrados os resultados para o escoamento do cascalho, onde a velocidade medida é representada em vermelho e as velocidades estimadas, em azul.

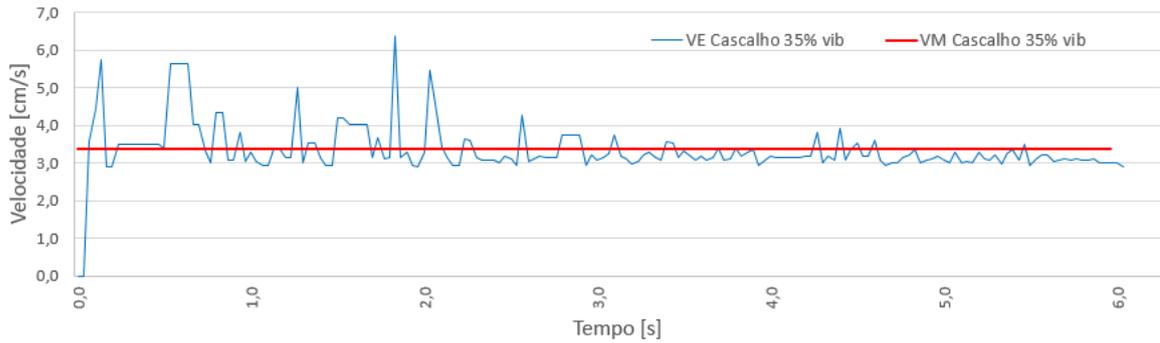
Tabela 13. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira.

Tipo de Fragmento	Intensidade de Vibração	Velocidade Real [cm/s]	Velocidade Média Estimada [cm/s]	Desvio [%]
Cascalho	0,25	0,696	0,656	5,7
	0,3	1,522	1,585	4,1
	0,35	3,371	3,155	6,4

Fonte: O autor.



### VALIDAÇÃO DA VELOCIDADE DE ESCOAMENTO PARA CALHA INTEIRA



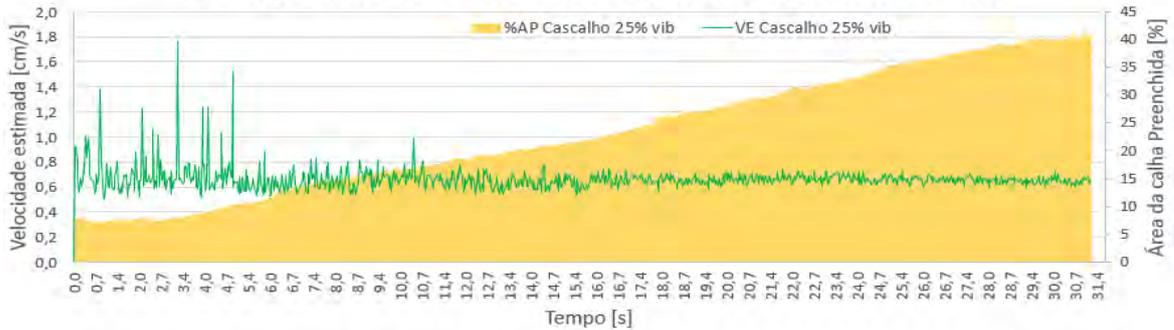
(C)

Figura 104. Validação da velocidade para o cascalho a (A) 25%, (B) 30% e (C) 35% de vibração utilizando calha inteira.

Fonte: O autor.

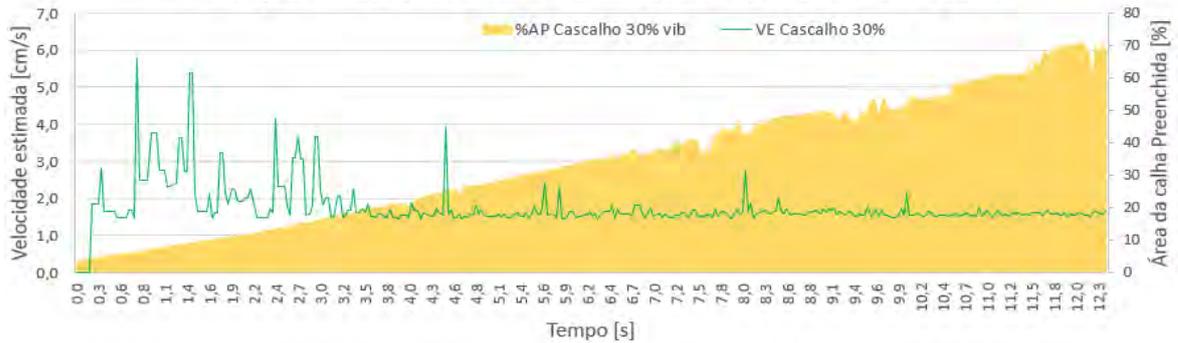
Como esperado, o aplicativo apresentou as mesmas limitações encontradas no Grupo III quando a %AP é inferior a 15%, o que é mostrado na Figura 105. Ainda assim, sua resposta foi considerada muito boa.

### RELAÇÃO ENTRE VELOCIDADE DE ESCOAMENTO E ÁREA PREENCHIDA

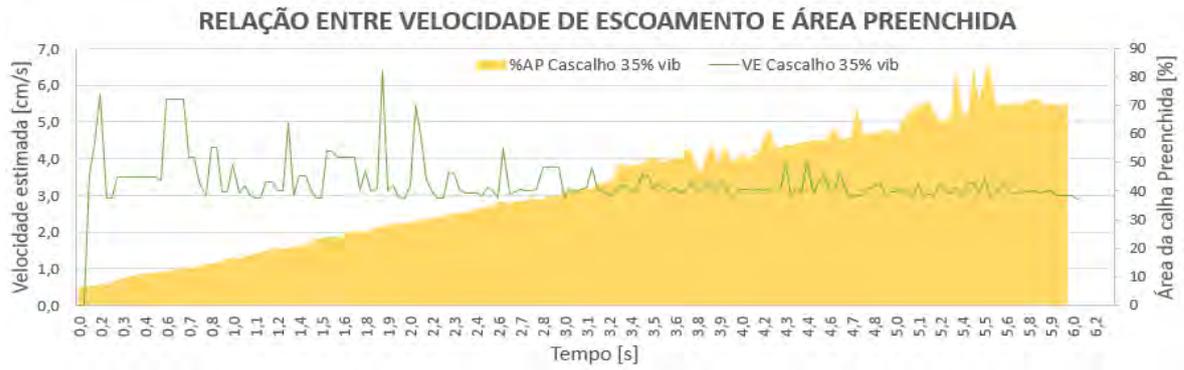


(A)

### RELAÇÃO ENTRE VELOCIDADE DE ESCOAMENTO E ÁREA PREENCHIDA



(B)



(C)

Figura 105. Relação entre vazão mássica estimada e %AP para o cascalho nas intensidades de vibração (A) 25%, (B) 30% e (C) 35%.

Fonte: O autor.

### 7.4.3 Estimativa da velocidade de escoamento – Final de Calha

Os resultados do algoritmo para o trecho final da calha são apresentados na Tabela 14. Na Figura 106 são mostrados graficamente os resultados, onde a velocidade medida é representada em vermelho e as velocidades estimadas, em azul. Da mesma forma, pode-se dizer que o aplicativo realizou boas estimativas, já que os desvios são menores que 10%, mas também apresentou as mesmas limitações quando a %AP é inferior a 15%, o que é mostrado na Figura 107.

Tabela 14. Validação da velocidade para vários sólidos em escoamento utilizando a calha inteira.

Tipo de Fragmento	Intensidade de Vibração	Velocidade Real [cm/s]	Velocidade Média Estimada [cm/s]	Desvio [%]
Cascalho	0,25	0,541	0,591	9,2
	0,3	1,282	1,328	3,6
	0,35	3,000	2,89	3,8

Fonte: O autor.

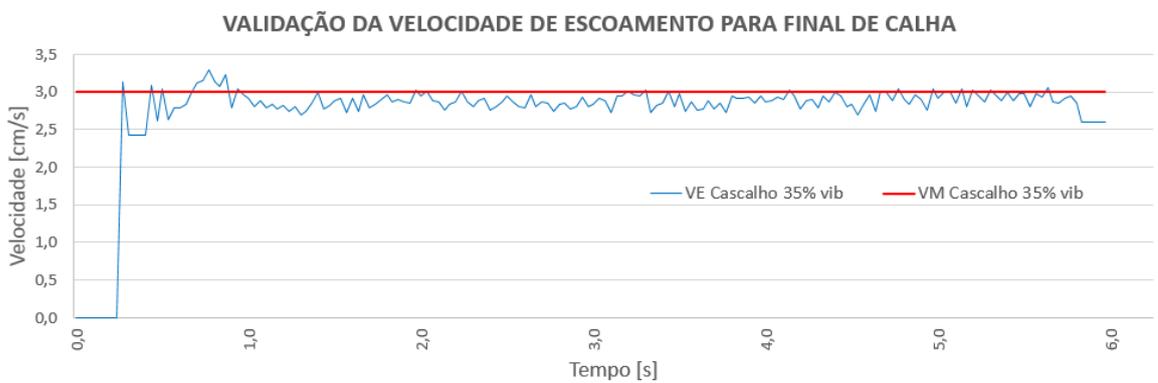
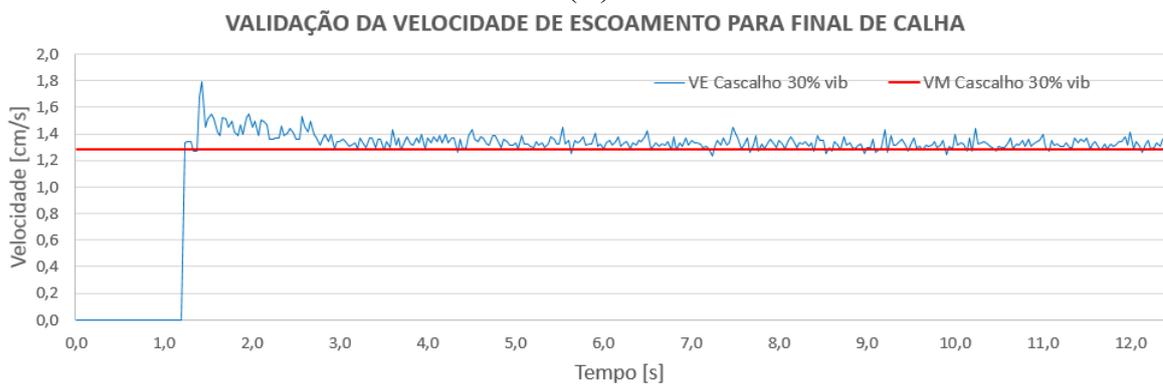
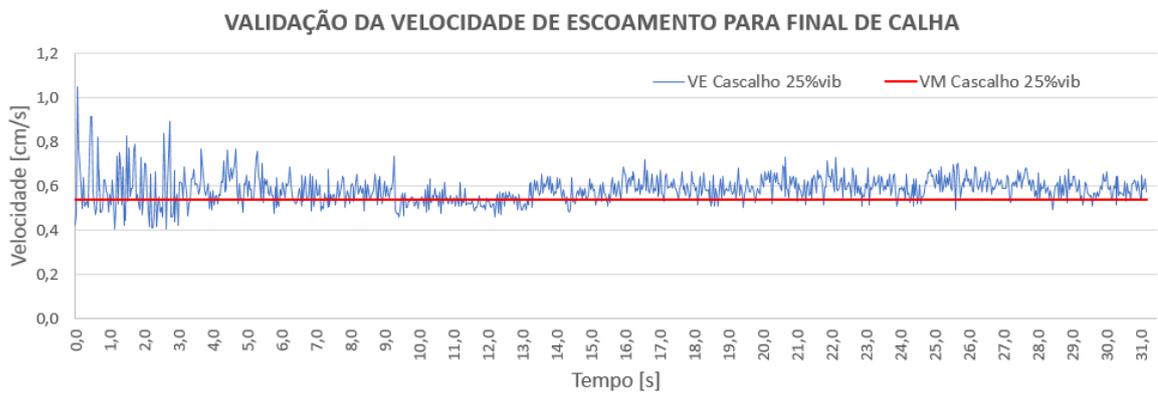
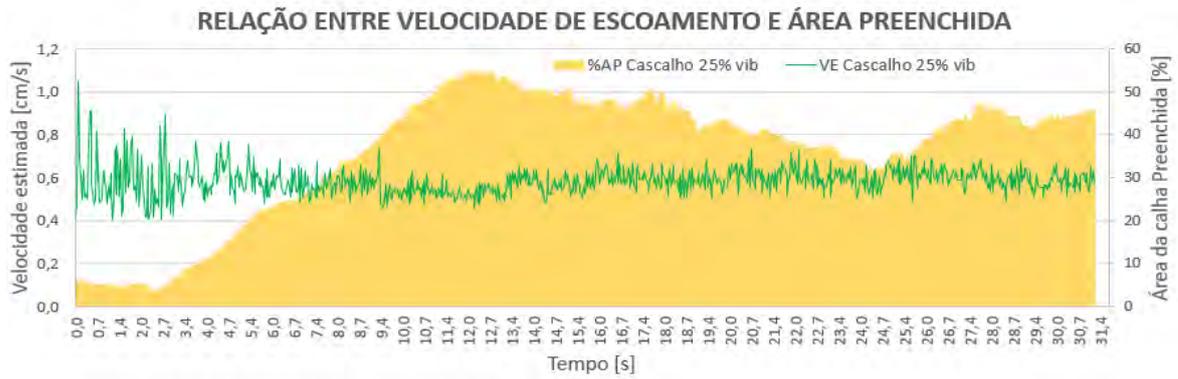
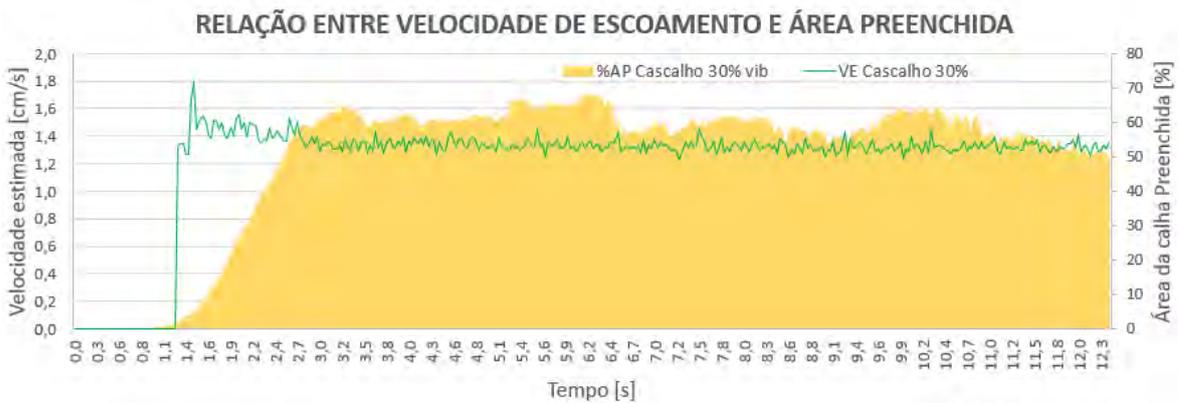


Figura 106. Validação da velocidade para o cascalho a (A) 25%, (B) 30% e (C) 35% de vibração utilizando um trecho da calha.

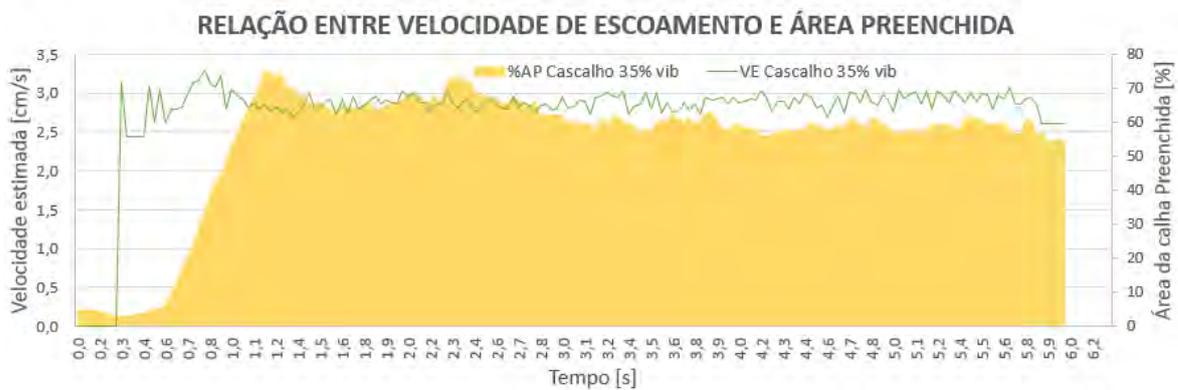
Fonte: O autor.



(A)



(B)



(C)

Figura 107. Relação entre vazão mássica estimada e %AP para o cascalho nas intensidades de vibração (A) 25%, (B) 30% e (C) 35% considerando um trecho da calha.

Fonte: O autor.

Assim como feito no grupo anterior, os descritores texturais contraste e homogeneidade foram comparados com a variável validada %AP como alternativa qualitativa para a estimativa de vazão mássica. O gráfico da Figura 108 mostra todos os descritores plotados com valores normalizados, evidenciando que as curvas, apesar de valores reais diferentes, possuem o mesmo comportamento.

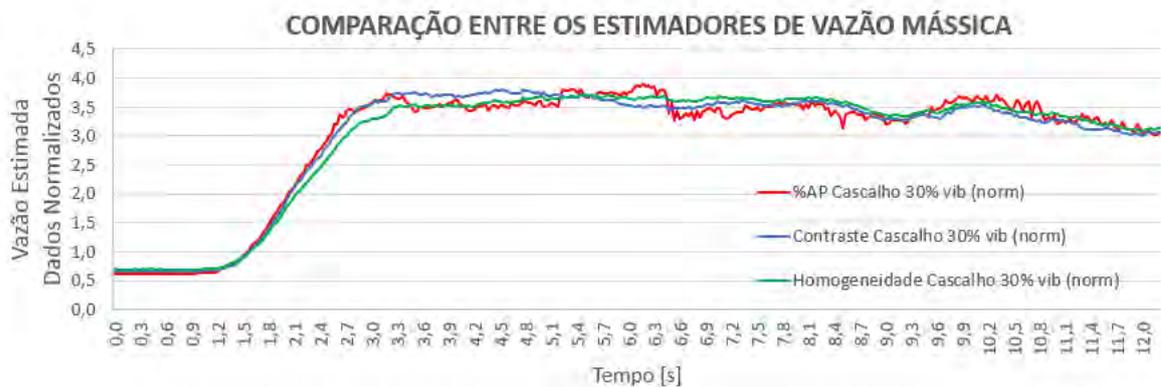


Figura 108. Relação entre estimadores de vazão para o cascalho utilizando quatro descritores e considerando calha inteira.

Fonte: O autor.

Como apresentado nos resultados, as alterações feitas no algoritmo fizeram com que o aplicativo proposto também fosse capaz de identificar o cascalho ensaiado em laboratório e estimar velocidade de escoamento. Além disso, mostra a possibilidade de, em trabalhos futuros, incorporar a estimativa de vazão mássica baseada em descritores texturais. O próximo passo para este aplicativo será a adaptação deste código para vídeos de peneiras reais, com a inserção das situações que indicariam possíveis instabilidades.

#### 7.4.4 Aplicativo 2 – Classificação dos Sólidos

Este aplicativo teve como objetivo classificar os cascalhos segundo tamanho e categoria utilizando redes neurais convolucionais. Além disso, o algoritmo também possui ferramentas para estimação de algumas características geométricas que podem servir como entrada para um sistema de controle de parâmetros de processo.

Como pode ser observado, a diferença visual entre as categorias (Figura 64) é pequena, o que faz com que o banco de imagens tenha padrões homogêneos, dificultando a diferenciação das classes. Dessa forma, utilizou-se uma técnica similar à descrita por Khojasteh et al. (2015), que consistiu no pré-tratamento do bando de dados: cada imagem passou por um processo de fracionamento, que a divide em imagens menores (Figura 109<sup>a</sup>).

Outra vantagem é que menos fragmentos estão presentes em cada uma das sub-imagens fornecidas à rede, o que permite uma avaliação mais detalhadas de cores, texturas e formas. Esse procedimento permite que as camadas convolucionais detectem e extraiam mais características, aumentando assim o potencial de diferenciação.

Neste trabalho foram testadas duas formatações diferentes: (i) sub-imagens de tamanho 300x300 *pixels*, levando a um banco com 6.100 dados (Figura 109B), chamado DS1; e (ii) sub-imagens de tamanho 600x600, levando a um banco com 2000 dados (Figura 109C), chamado DS2.

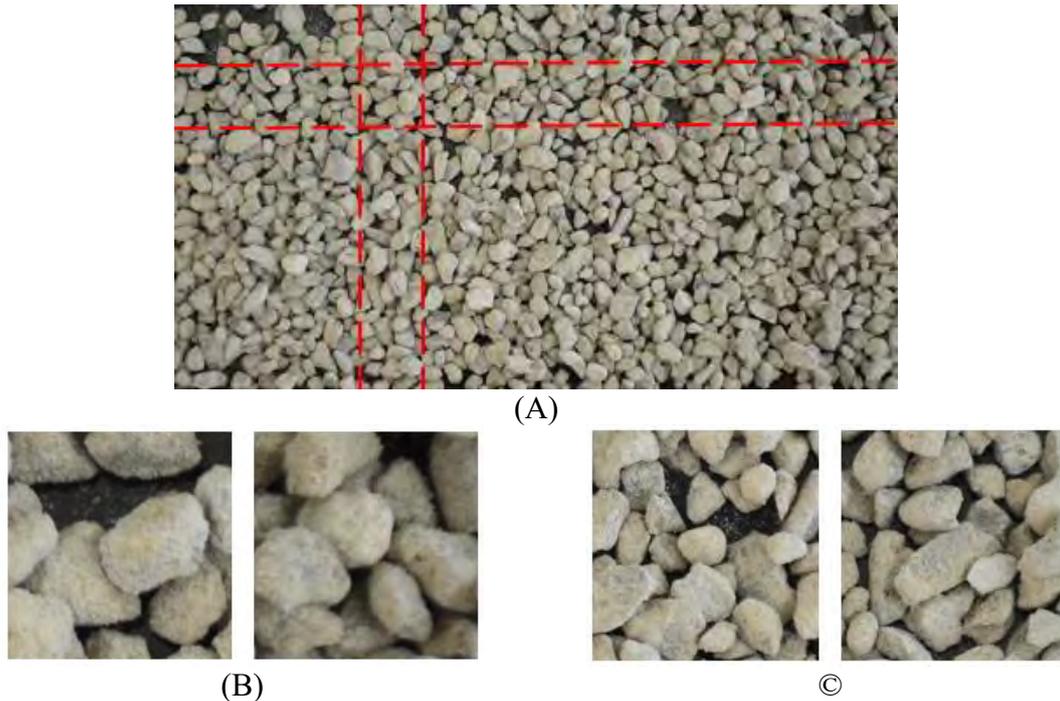
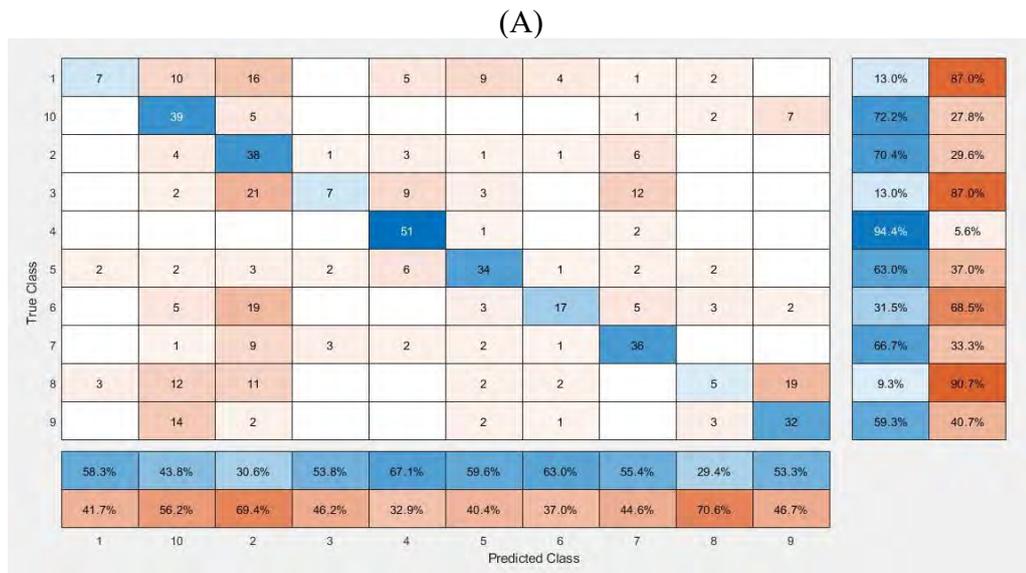


Figura 109. Pré-tratamento do banco de imagens. (A) Técnica de fragmentação. (B) Sub-imagens 300x300. (C) Sub-imagens 600x600.

Fonte: O autor.

As simulações foram feitas inicialmente utilizando a rede pré-treinada *AlexNet*, onde se empregou a técnica de *transfer learning* e o treinamento englobou somente o ajuste dos pesos das camadas completamente conectadas, responsáveis pela classificação. A CNN recebeu como entrada o DS1, mas os resultados não foram bons o suficiente para que esta fosse a configuração escolhida para as classificações seguintes. O modelo apresentou 60,25% de acurácia para a classificação de tamanho e 46,48% para a classificação de categoria. Vale destacar que para conseguir esse resultado foi necessário realizar uma etapa de remoção de ruídos no DS1, eliminando imagens onde somente se apresentava fundo, sem cascalhos. Os resultados foram apresentados a seguir em forma de Matriz Confusão, apresentadas na Figura 110.



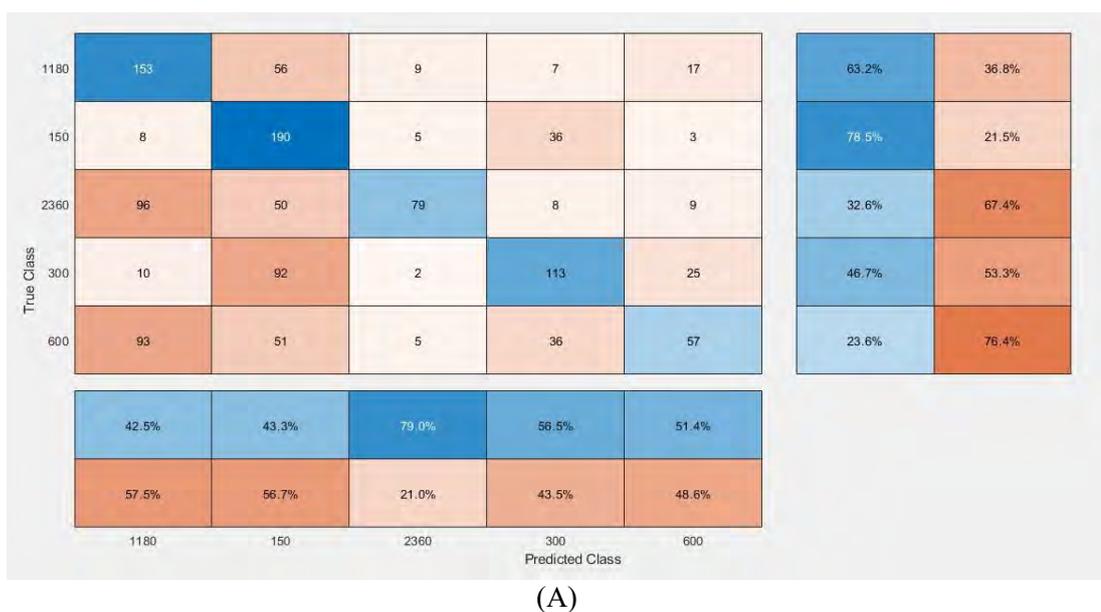


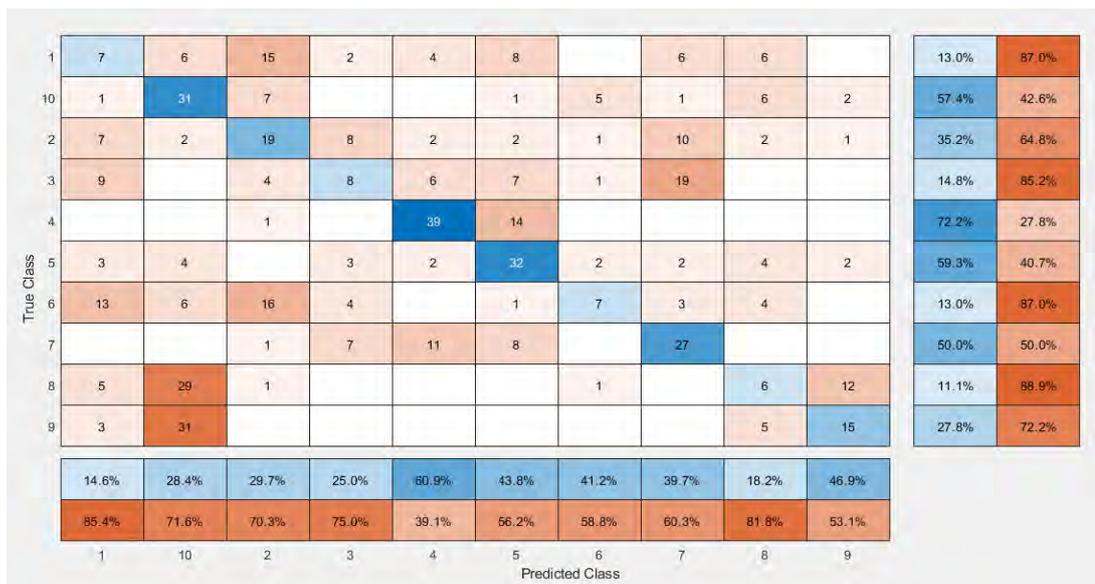
(B)

Figura 110. Matriz Confusão da classificação do cascalho segundo: (A) tamanho, utilizando DS1 e rede *AlexNet*. Acurácia: 60,25%; (B) categoria, utilizando DS1 e rede *AlexNet*. Acurácia: 46,48%.

Fonte: O autor.

Em seguida as simulações foram refeitas utilizando uma rede não pré-treinada, mas com uma estrutura muito semelhante à da *AlexNet*. O objetivo foi comparar o desempenho da rede pré-treinada com a rede construída do zero. O mesmo banco de dados, sem ruídos, foi fornecido para a rede não pré-treinada e os resultados foram inferiores, com 48,51% para tamanho e 36,48% para categoria. Esse desempenho pode ser justificado pelo ajuste não muito fino das camadas convolucionais, que precisariam de maior variabilidade de imagens de treinamento para detectar e extrair de forma mais precisa as características. Detalhes de como uma CNN funciona estão na fundamentação teórica do Apêndice 1. Os resultados foram apresentados a seguir em forma de Matriz Confusão, apresentadas na Figura 111.





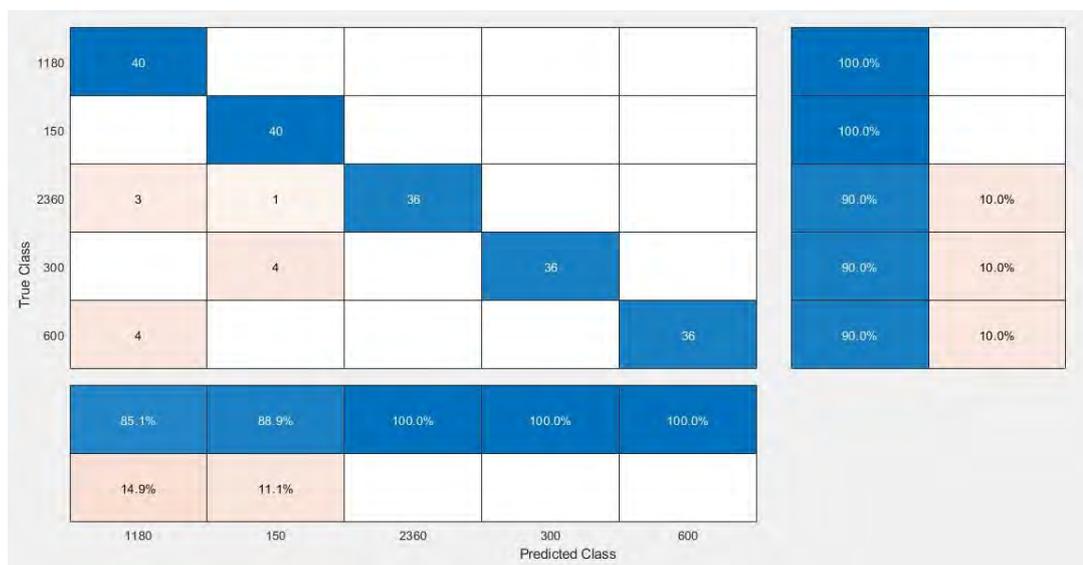
(B)

Figura 111. Matriz Confusão da classificação do cascalho segundo (A) tamanho, utilizando DS1 e rede não pré-treinada. Acurácia: 48,51%; (B) categoria, utilizando DS1 e rede não pré-treinada. Acurácia: 36,48%.

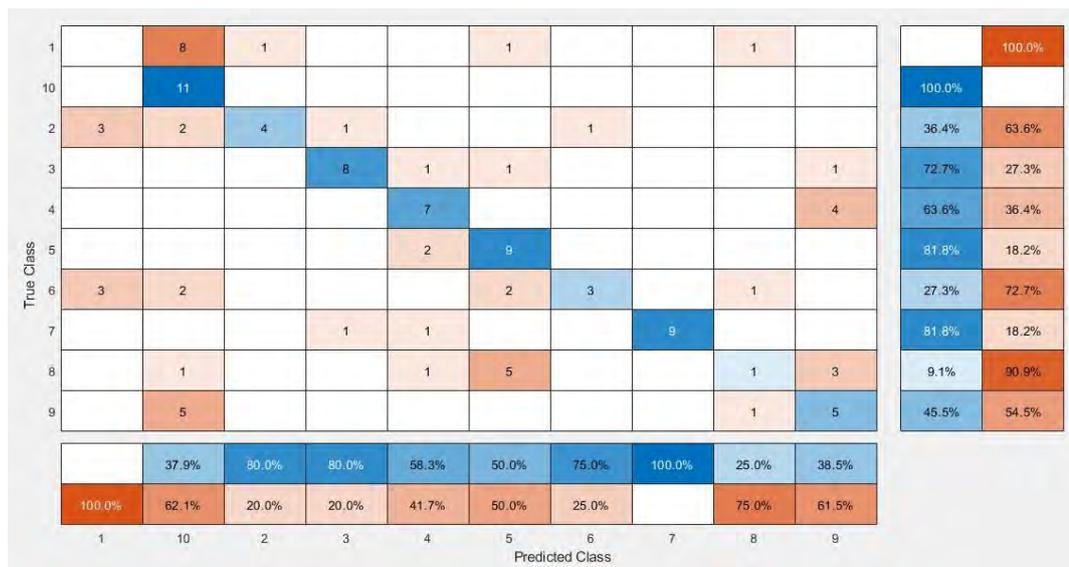
Fonte: O autor.

Depois dessa análise, como tentativa de aumentar a precisão, testou-se o DS2. A escolha por aumentar o tamanho das sub-imagens ocorreu pelo fato de que, nos casos onde há fragmentos muito grandes, não é possível identificar bordas, o que dificulta a detecção e extração de características pelas camadas convolucionais. Isso é refletido na etapa de classificação, que consequentemente recebe menos atributos, podendo gerar resultados incorretos, classificações equivocadas.

De fato, essa mudança aumentou significativamente a performance da CNN, que atingiu com a rede *AlexNet* 94% de acurácia para tamanho e 61,67% para categoria, o melhor resultado encontrado para todas as simulações, que é ilustrado na Figura 112 na forma de Matrizes Confusão.



(A)



(B)  
 Figura 112. Matriz Confusão da classificação do cascalho segundo (A) tamanho, utilizando DS2 e rede *AlexNet*. Acurácia: 94,00%; (B) categoria, utilizando DS2 e rede *AlexNet*. Acurácia: 61,67%.  
 Fonte: O autor.

Os resultados apresentados indicam que a CNN tem alto poder de classificação dos cascalhos quanto ao tamanho, o que pode ser muito vantajoso para identificar se há ou não cascalhos de desmoronamento nas amostras, já que esses, em geral, são maiores que os demais.

Por outro lado, a capacidade de diferenciação das amostras quanto a categoria ainda precisa ser melhorada. O treinamento das camadas completamente conectadas precisa que as correspondências entre imagem e composição estejam corretas para o correto treinamento, o que neste caso não pode ser garantido porque ainda não foram recebidos os resultados das análises de DRX. Sendo assim, a resposta tida como esperada pela CNN equivale à previsão do geólogo em plataforma, que tem como ferramenta, muitas vezes, apenas um microscópio.

O próximo passo desta classificação é repetir todas as simulações referentes a categoria assim que o resultado do DRX for liberado.

A segunda ferramenta disponível neste aplicativo calcula descritores geométricos de tamanho, área e perímetro para estimar propriedades estatísticas, dentre as quais destacam-se arredondamento, circularidade e excentricidade, além do tamanho médio de partículas.

Na Figura 113 é apresentado um exemplo da aplicação dessas ferramentas onde em (A) tem-se a imagem original, fornecida como entrada do aplicativo e em (B), a imagem binarizada, ponto de partida para o cálculo das estimativas.

Nesta figura são detectados 69 objetos, dentre os quais seis, com a numeração em seu interior, foram selecionados para análise mais detalhada e para a validação das estimativas. O algoritmo retornou uma matriz onde cada linha representa um objeto e cada coluna, um descritor. Os objetos foram organizados por ordem de tamanho, sendo assim, a numeração mostrada acima não é aleatória, mas representa a posição que o objeto ocupa nessa matriz.

Para melhor visualização dos fragmentos escolhidos, estes foram destacados e mostrados, em proporção de tamanho, na Figura 114. Os resultados da análise são mostrados nas tabelas e imagens a seguir.

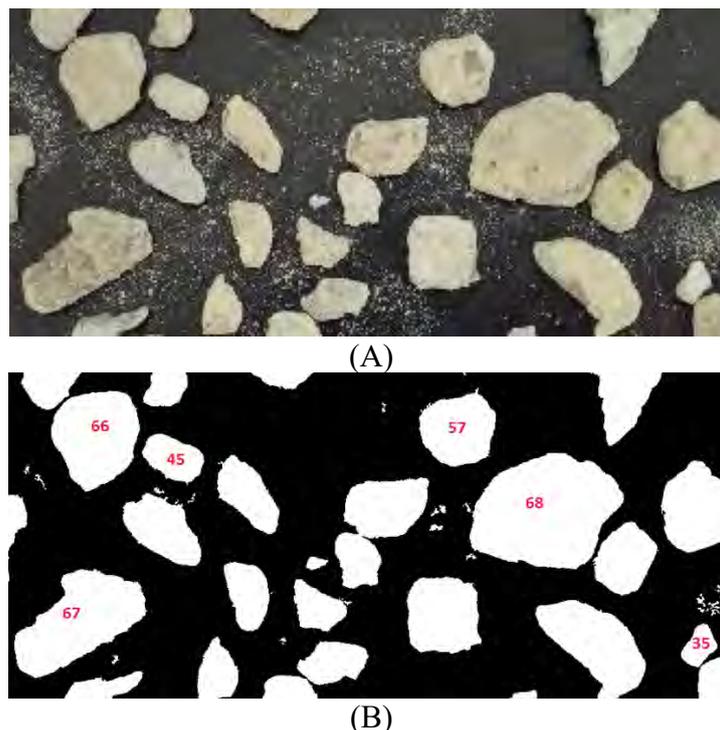


Figura 113. (A) Imagem de entrada do aplicativo 2. (B) Imagem binarizada utilizada no cálculo das propriedades dos objetos.  
Fonte: O autor.

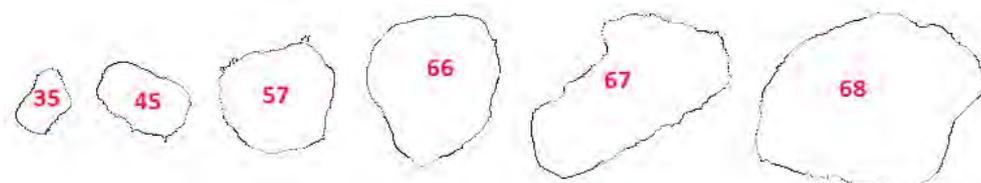


Figura 114. Bordas detectadas dos cascalhos escolhidos para validação. Fonte: O autor.

Na Tabela 15 são listados os descritores área e perímetro e as propriedades arredondamento, circularidade e excentricidade. Comparando os resultados obtidos com os sólidos destacados na Figura 114, tem-se que o de maior circularidade, ou seja, o que mais se aproxima de um círculo perfeito, é o fragmento 57, resultado coerente com a imagem. O fragmento que possui a menor circularidade é o 67, justamente o que apresenta a maior excentricidade, ou seja, é o que mais se aproxima de uma elipse perfeita. Já o fragmento 66 é o que apresenta maior arredondamento, ou seja, o que tem as bordas mais uniformes.

Tabela 15 Descritores geométricos e propriedades estatísticas.

Objeto	Área (mm <sup>2</sup> )	Perímetro (mm)	Arredondamento	Circularidade	Excentricidade
35	5,8	9,6	0,78	0,61	0,78
45	12,3	14,6	0,72	0,60	0,79
57	26,2	22,3	0,67	0,92	0,36
66	39,6	24,3	0,84	0,85	0,51
67	49,6	31,3	0,64	0,47	0,87

<b>68</b>	78,4	35,8	0,77	0,73	0,67
-----------	------	------	------	------	------

Fonte: O autor.

Na Tabela 16 é apresentada a estimativa de tamanho do maior e menor eixo para cada um dos fragmentos, onde o tamanho real foi medido em laboratório com auxílio de paquímetro. O aplicativo calcula todos os eixos em todas as direções e retorna os valores máximo e mínimo encontrados.

Tabela 16 Validação do tamanho de partícula.

Objeto	Menor eixo (mm)		Maior Eixo (mm)		Erro (%)	
	Real	Estimado	Real	Estimado	Menor Eixo	Maior Eixo
<b>35</b>	2,0	2,2	3,3	3,5	9,6	5,1
<b>45</b>	3,0	3,1	4,7	5,1	5,5	8,1
<b>57</b>	5,6	5,9	6,1	6,0	5,2	1,2
<b>66</b>	6,7	6,7	8,3	7,7	0,4	7,1
<b>67</b>	5,6	4,7	11,5	11,7	23,8	1,3
<b>68</b>	8,8	8,7	12,1	11,7	1,7	3,6

Fonte: O autor.

Como pode ser observado na coluna do erro, apenas o menor eixo da partícula 67 apresentou desvio maior que 10%. Tal fato pode estar associado à irregularidade da partícula, onde a medida real de menor eixo pode não ter sido feita, de fato, no menor eixo, uma vez que a escolha do menor e maior eixos medidos dependem da capacidade visual do operador. Ainda assim, os resultados podem ser considerados satisfatórios.

As análises geométricas podem ser utilizadas como ferramentas estatísticas de controle do padrão dos sólidos, onde pode ser definido um intervalo em que as propriedades estejam com valores estimados dentro do normal de operação. Caso seja de interesse, um alerta pode ser acionado quando algum objeto apresentar qualquer das propriedades fora desse intervalo, o que indicaria algum problema operacional.

## 7.5 Grupo V

Os vídeos dos ensaios em peneira realizados por Barbosa (2018) foram gentilmente cedidos para compor o banco de imagens referente ao Grupo V, cujo objetivo foi avaliar a performance do aplicativo para escoamento de sólidos em via úmida, realidade encontrada em algumas peneiras reais de deck duplo ou triplo da Petrobras.

Nesse tipo de peneira os cascalhos de maior tamanho são retidos na primeira tela, apresentando aspecto mais seco, como nos ensaios dos grupos anteriores realizados no LEF/URRJ. Por outro lado, os sólidos passantes, por possuírem diâmetro menor, retêm mais fluido de perfuração, apresentando o aspecto “molhado”, conforme pode ser visto na Figura 115 para o escoamento de areia em suspensão aquosa de 0,1% de goma xantana realizado no Laboratório de Automação Industrial da FEQ/UFU.



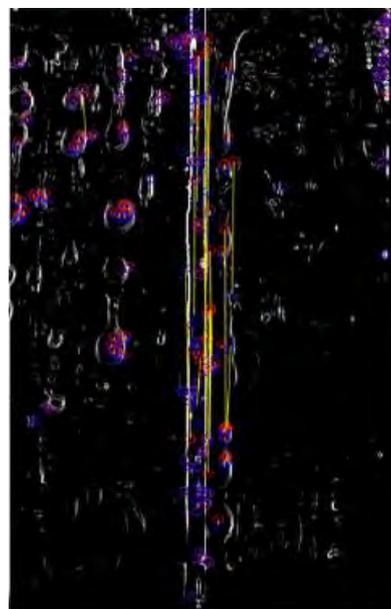
Figura 115. Frame retirado de vídeo do experimento 3.  
Fonte: O autor.

### 7.5.1 Detecção – Velocidade de Escoamento

Os vídeos dos 26 experimentos realizados por Barbosa (2018) foram submetidos ao código ajustado para o Grupo IV. Como exemplo, as imagens na Figura 116 ilustram em (A) um frame retirado do experimento 8 e em (B), o mesmo frame após a segmentação e detecção de pontos de correspondência para cálculo da velocidade.



(A)



(B)

Figura 116. (A) Frame original retirado do experimento 8.  
(B) Frame após segmentação pelo método de Fourier.

Fonte: O autor.

Como pode ser visto nessas imagens, a etapa de detecção não apresentou resultados tão bons quanto os encontrados para partículas secas. O realce das bordas ocorre apenas para os

trechos onde o contraste entre suspensão e plano de fundo é maior e isso dificulta tanto as estimativas de %AP quanto de velocidade, porque considera apenas uma parte reduzida do material em escoamento.

Os resultados de velocidade obtidos para este método são mostrados na Figura 117, onde os pontos em preto representam os resultados experimentais obtidos por Barbosa (2018), com a média e valores máximos e mínimos encontrados nas 6 medições. Os pontos em vermelho representam a média dos pontos estimados pelo aplicativo. Vale destacar que as estimativas foram calculadas a cada frame, variando de 2000 a 5000 pontos em todo o escoamento.

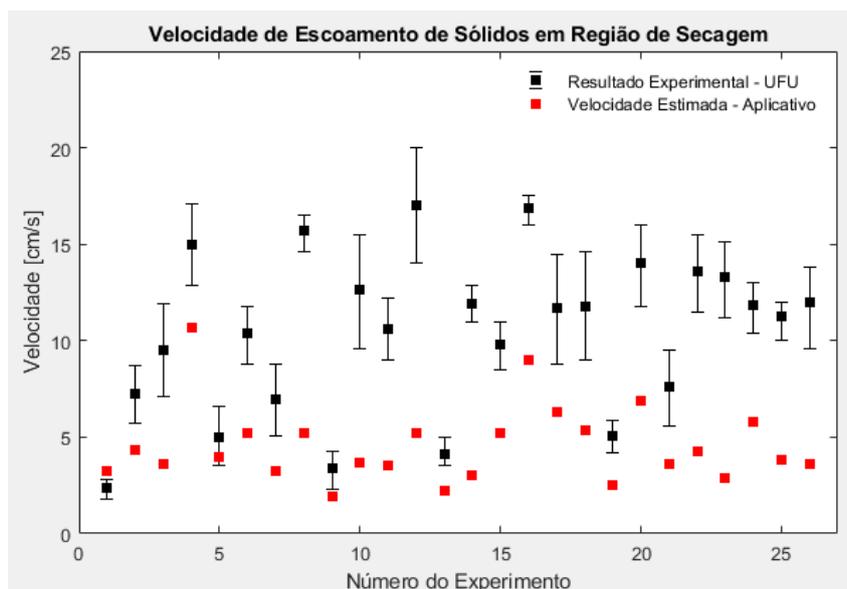
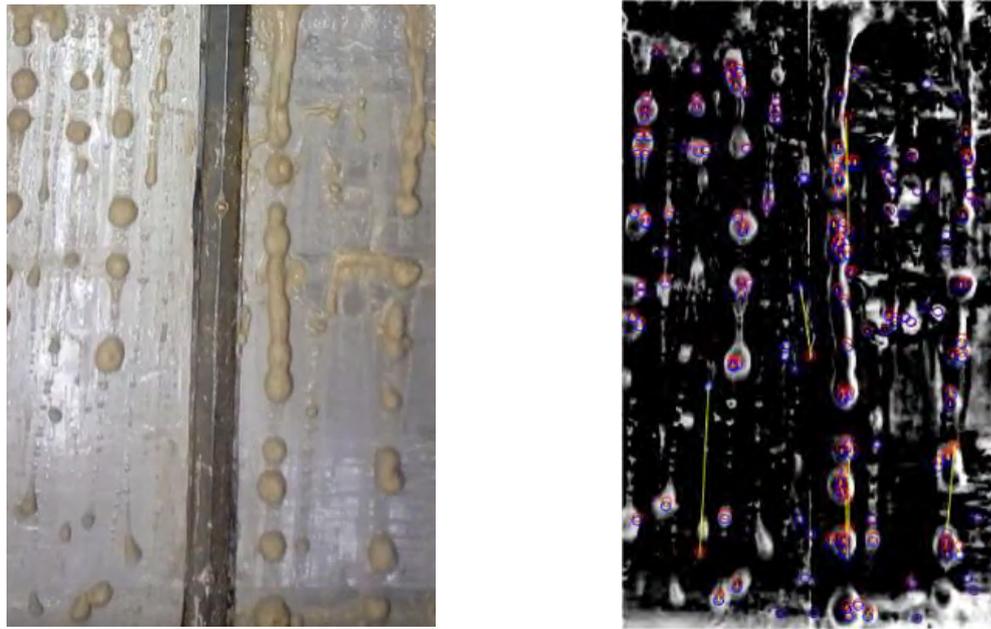


Figura 117. Resultado da velocidade estimada com segmentação de Fourier.  
Fonte: O autor.

Vários aglomerados se deslocam com velocidades diferentes, inclusive em sentido contrário ao escoamento. Além disso, por se tratar de uma suspensão, o tamanho e forma desses aglomerados se modifica ao longo do escoamento, portanto justifica-se que o método de Fourier não seja capaz de identificar essa variedade pela limitação na detecção. Com isso, foram necessários ajustes na etapa de segmentação.

O método que apresentou os melhores resultados utiliza a Transformada de Wavelet (TW) para detecção e realce de bordas. Com mais objetos detectados, foi possível obter resultados mais confiáveis e mais próximos das medidas experimentais. Na Figura 118 são mostradas imagens do mesmo frame avaliado anteriormente do experimento 8, mas agora segmentado por TW, onde fica evidenciada a diferença na detecção.

Na Figura 119 são apresentados os novos resultados para estimativas das velocidades, em que a imagem segmentada por TW foi fornecida como entrada para o algoritmo de detecção de pontos de correspondência. Os pontos em preto representam os resultados obtidos por Barbosa (2018) com a média e valores máximos e mínimos encontrados, e os pontos em vermelho representam a média dos pontos estimados pelo aplicativo. Este método se mostrou mais eficiente do que o anterior.



(A) (B)  
 Figura 118. (A) Frame original retirado do experimento 8.  
 (B) Frame após segmentação pelo método de Wavelets.  
 Fonte: O autor.

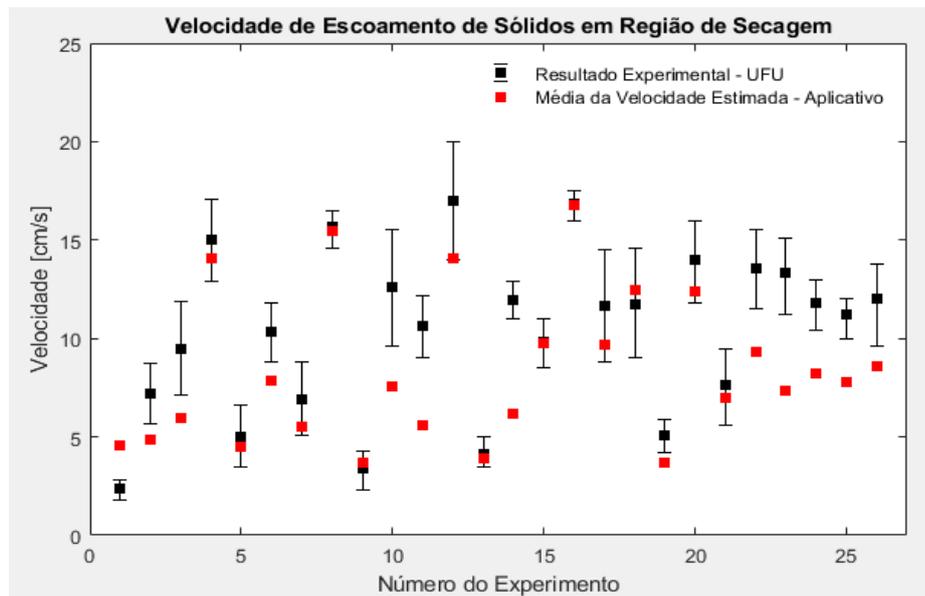


Figura 119. Resultado da velocidade estimada com segmentação com wavelets.  
 Fonte: O autor.

Na Tabela 17 são apresentados os valores máximos e mínimos obtidos experimentalmente por Barbosa (2018) e os valores médios estimados pelo software de visão computacional. As cédulas em verde correspondem aos experimentos em que foi encontrado um valor médio estimado dentro da faixa experimental, com um erro de até 10% em relação aos limites inferior ou superior. Nas cédulas em vermelho o desvio foi maior do que 10%.

Tabela 17 Resultado da estimativa de velocidade para os experimentos com suspensão de areia e goma xantana 0.1%.

Nº Experimento	Vel Exp. Min [cm/s]	Vel Exp. Máx [cm/s]	V Est. [cm/s]
1	1,8	2,8	4,7
2	5,7	8,7	4,8
3	7,1	11,9	6,0
4	12,9	17,1	14,1
5	3,5	6,6	4,5
6	8,8	11,8	5,5
7	5,1	8,8	5,6
8	14,6	16,5	15,1
9	2,3	4,3	3,7
10	9,6	15,5	7,7
11	9,0	12,2	5,7
12	14,0	20,0	13,8
13	3,5	5,0	4,0
14	11,0	12,9	6,2
15	8,5	11,0	9,6
16	16,0	17,5	16,8
17	8,8	14,5	9,8
18	9,0	14,6	8,8
19	4,2	5,9	3,7
20	11,8	16,0	12,4
21	5,6	9,5	4,4
22	11,5	15,5	9,2
23	11,2	15,1	7,3
24	10,4	13,0	8,2
25	10,0	12,0	7,8
26	9,6	13,8	8,6

Fonte: O autor.

A seguir serão apresentados os gráficos das velocidades medidas e estimadas ao longo do tempo para alguns experimentos. Em vermelho estão os limites máximo e mínimo de velocidades e em azul, a velocidade média, todas estimadas por Barbosa (2018). Em preto, a velocidade estimada a cada frame pelo aplicativo proposto neste trabalho.

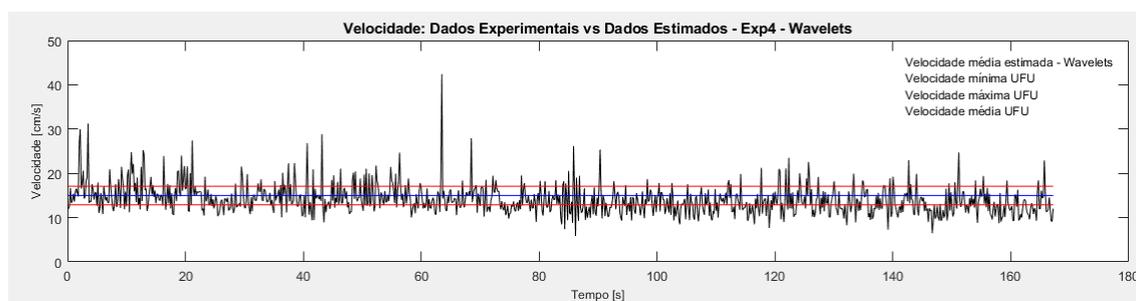


Figura 120. Velocidade estimadas ao longo do tempo para o experimento 4. Fonte: O autor.

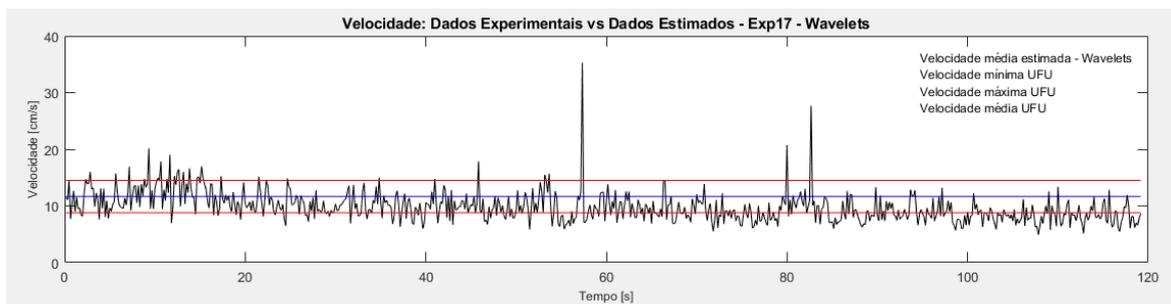


Figura 121. Velocidade estimadas ao longo do tempo para o experimento 17. Fonte: O autor.

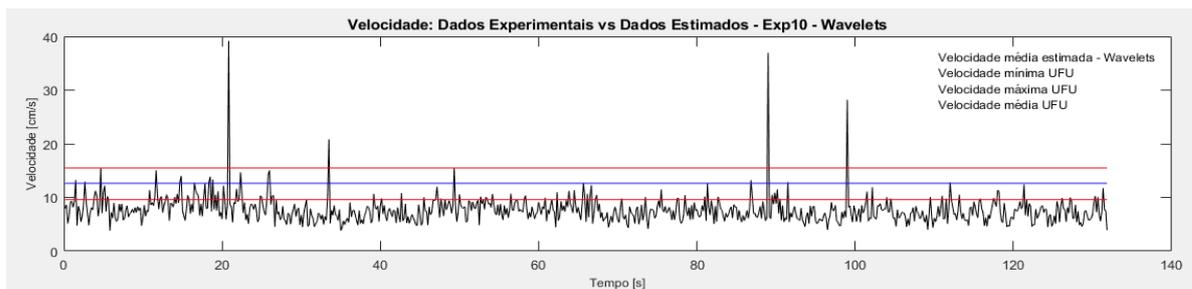


Figura 122. Velocidade estimadas ao longo do tempo para o experimento 10. Fonte: O autor.

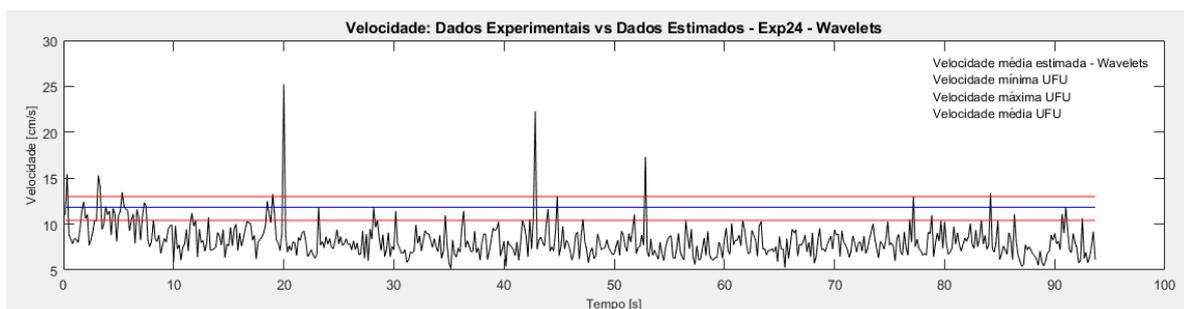


Figura 123. Velocidade estimadas ao longo do tempo para o experimento 24. Fonte: O autor.

Os dois primeiros gráficos (Figura 120 e Figura 121) mostram resultados onde as velocidades estimadas nos dois trabalhos são equivalentes. Os dois gráficos seguintes (Figura 122 e Figura 123) mostram os casos em que o mesmo não ocorreu.

Segundo análise da Tabela 17, os experimentos 10 e 17 possuem médias estimadas fora do intervalo esperado com erro maior que 10%. Entretanto, observa-se que existem alguns momentos durante o escoamento em que os valores estimados estão dentro dessa faixa aceitável. O estudo anterior, realizado por Barbosa (2018), utilizou 6 medições aleatórias ao longo do tempo de vídeo e esse estudo propõe pelo menos 2000 medidas, então talvez as metodologias não possam ser comparadas com tanta rigidez. Ainda assim, os resultados obtidos foram considerados bons.

### 7.5.2 Detecção – Porcentagem da tela na região de secagem preenchida por sólidos

Para essa estimativa utilizou-se inicialmente a segmentação baseada no espaço de cores, visto que a técnica anterior não apresentou bons resultados de detecção. O objetivo foi avaliar se serão encontrados resultados coerentes com os fornecidos pelo trabalho de Barbosa (2018). Na Figura 124 é apresentado o panorama geral dos resultados encontrados e na Figura 125 dois exemplos de detecção.

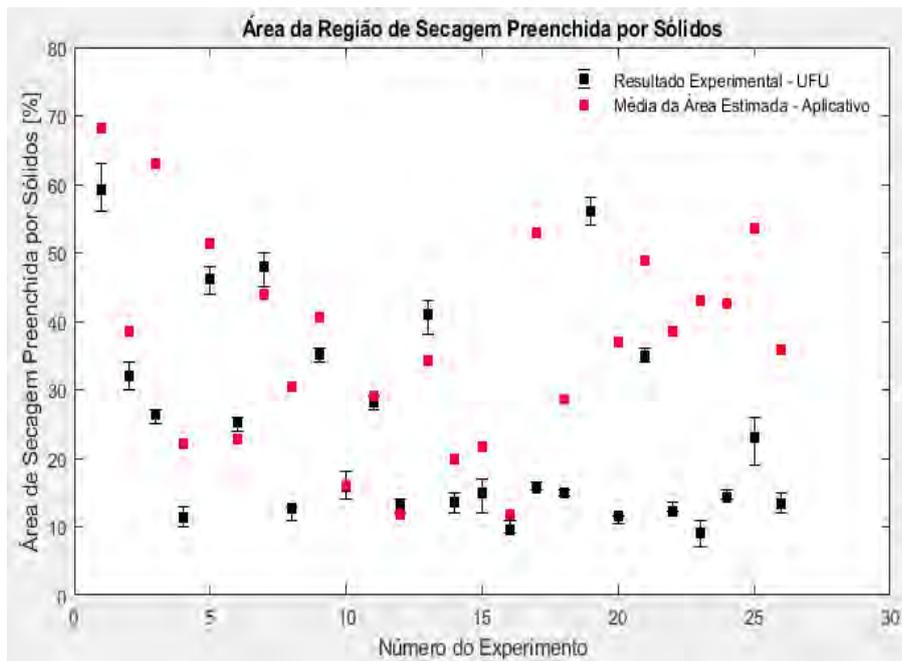


Figura 124. Resultado da %AP com segmentação por cores para todos os experimentos. Fonte: O autor.

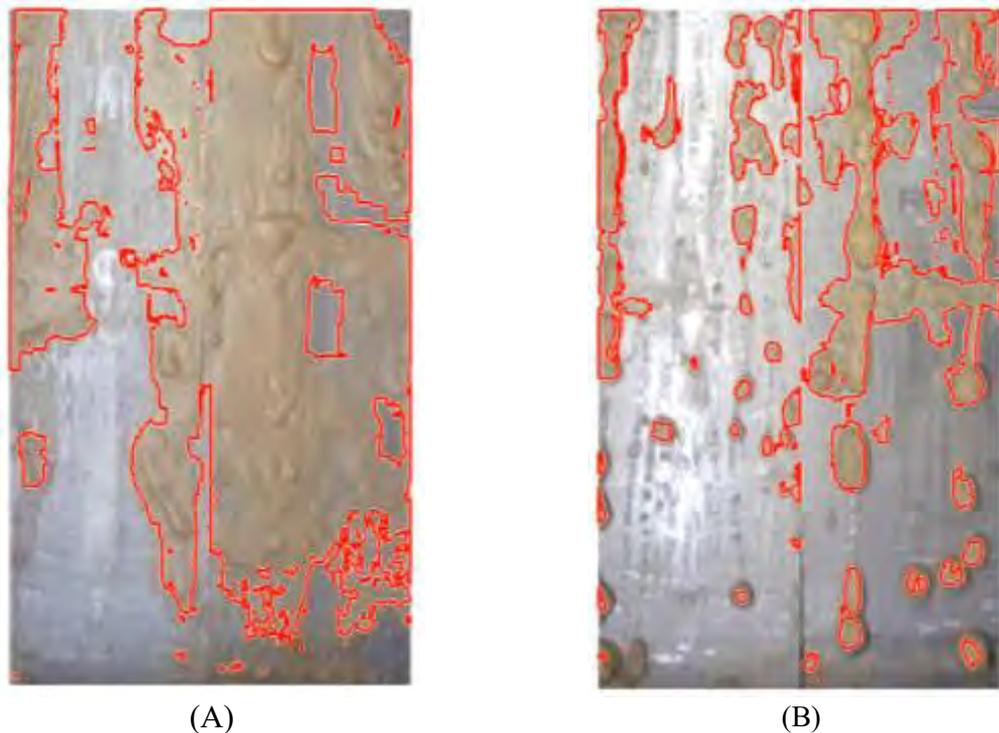


Figura 125. Resultado da %AP com segmentação por cores para os experimentos (A) 9 e (B) 15. Fonte: O autor.

Avaliando a resposta obtida na Figura 124, percebe-se que em poucos casos é possível obter valores correspondentes de %AP e que, em sua maioria, os valores estimados estão acima dos esperados. Entretanto, na Figura 125 é possível verificar que os objetos foram segmentados de forma satisfatória, sendo que o mesmo ocorreu na maioria dos casos. Avaliando os dois

exemplos numericamente, tem-se que a %AP estimada foi de 59,3% e 31,5%, respectivamente, para os experimentos 9 e 15. A %AP fornecida por Barbosa (2018) para os mesmos experimentos foi de 35,2% e 14,9%, respectivamente.

Isso pode acontecer devido às características da área selecionada como recorte para análise. Na Figura 126, mostrada anteriormente no capítulo de revisão de literatura, mostra o recorte selecionado como região de secagem para passar pelo processo de binarização. Observa-se que o trecho metálico no centro da peneira, o suporte para a tela, apesar de não ser selecionado como objeto é considerado para a medida de pixels total do recorte. Eventualmente podem surgir bordas metálicas que não correspondem à tela, como sugerido na imagem ilustrativa e, além disso, nem toda suspensão pode ter sido selecionada manualmente. Tudo isso faz com que a área considerada como plano de fundo seja maior e consequentemente, a %AP encontrada seja menor.

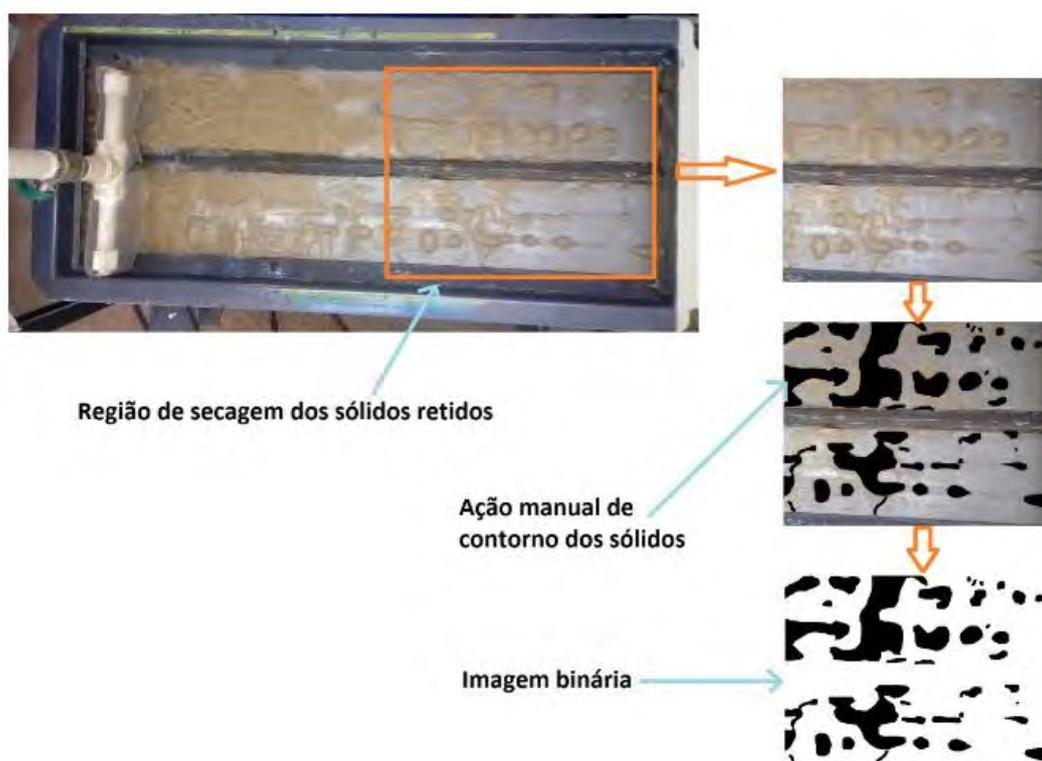


Figura 126. Resposta da detecção da porcentagem da área da região de secagem preenchida por sólidos. Fonte: Barbosa, 2018.

Apesar de apresentar resultados animadores, este método de detecção não é o mais adequado para implementação no aplicativo, já que a coloração da lama de perfuração pode variar de acordo com a composição do fluido de perfuração e da formação geológica perfurada. Sendo assim, avaliou-se o uso de redes neurais convolucionais para essa tarefa.

Para tanto, a mesma CNN dos grupos anteriores foi novamente treinada, agora utilizando imagens retiradas dos vídeos dos 26 experimentos. O banco de imagens foi organizado de forma que quatro classes de preenchimento pudessem ser adotadas: muito baixo, baixo, médio e alto. A primeira classe recebeu as imagens dos ensaios com média de %AP menor que 10%; a segunda classe, entre 10% e 30%; a terceira classe, entre 30% e 50%; e a última classe, maiores que 50%. A seguir são mostrados os resultados para o treinamento e a resposta obtida em forma de matriz confusão.

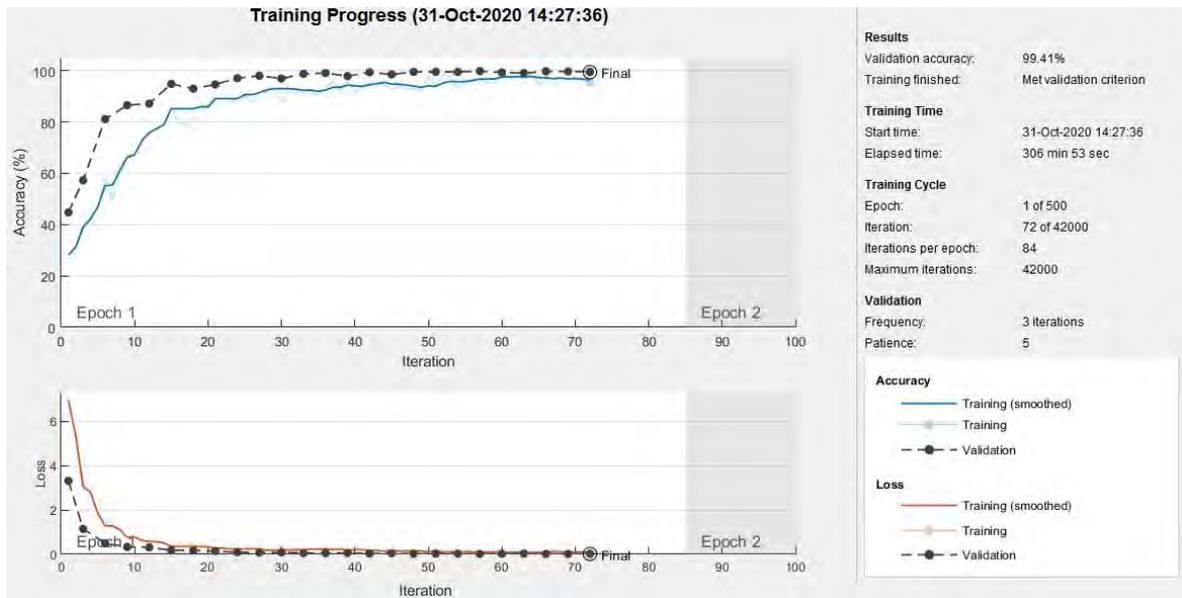


Figura 127. Treinamento da CNN dividida em 4 classes para os ensaios com suspensão de areia.  
 Fonte: O autor.

True Class	Alto	338				100.0%	
	Baixo		333	5		98.5%	1.5%
	Muito Baixo			338		100.0%	
	Médio				338	100.0%	
		100.0%	100.0%	98.5%	100.0%		
				1.5%			
		Alto	Baixo	Muito Baixo	Médio		
		Predicted Class					

Figura 128. Resultado da CNN dividida em 4 classes.  
 Fonte: O autor.

A matriz confusão ilustrada na Figura 128 mostra bons resultados, sobretudo em se tratando de um procedimento em que a imagem foi fornecida à rede sem nenhum tipo de pré-processamento. Sendo assim, modificou-se o banco de imagens de forma a classificá-lo em mais grupos, agora separados a cada 10% de preenchimento de calha, segundo valor médio de referência. Os resultados obtidos são apresentados a seguir.

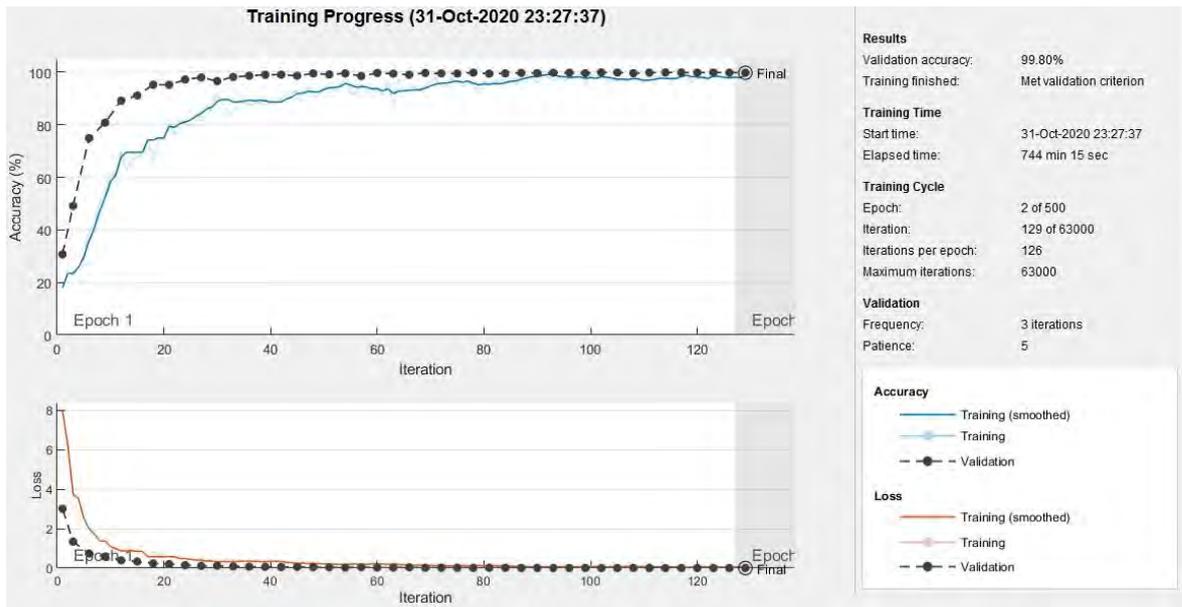


Figura 129. Treinamento da CNN dividida em 6 classes para os ensaios com suspensão de areia.  
 Fonte: O autor.

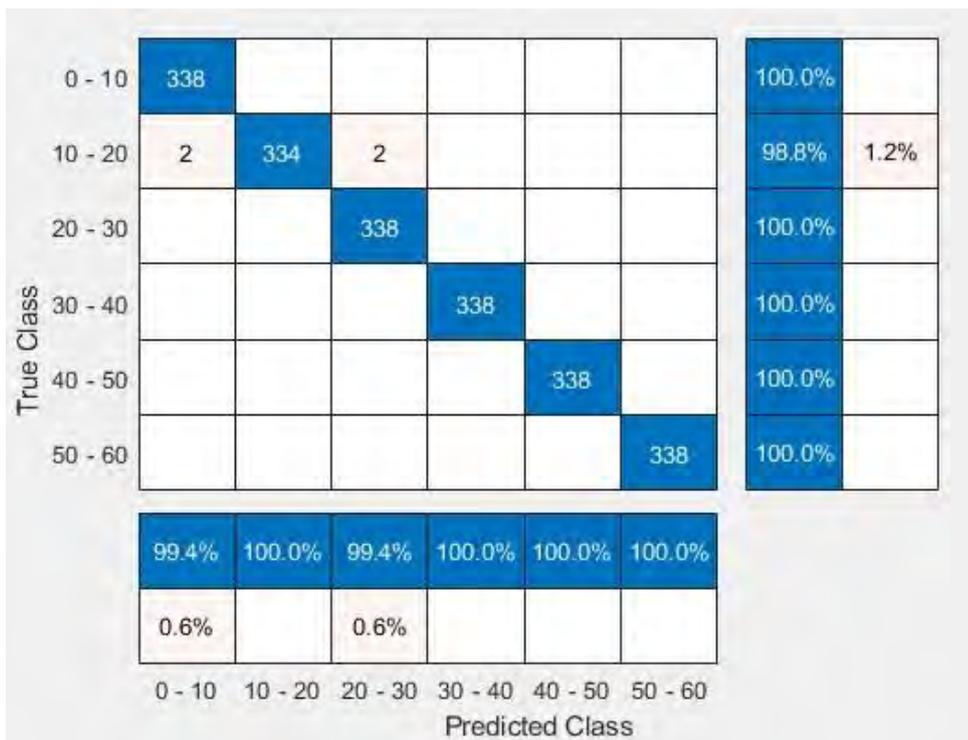


Figura 130. Resultado da CNN dividida em 6 classes.  
 Fonte: O autor.

Mais uma vez foram obtidos resultados animadores. Os próximos passos para aperfeiçoamento dessa técnica são a adequação da CNN para tarefas preditivas, de maior interesse para o monitoramento de processos.

### 7.5.3 Avaliação de tempo de processamento

Como o objetivo deste trabalho foi desenvolver um aplicativo que seja capaz de realizar o monitoramento do escoamento de cascalhos em tempo real, a avaliação do tempo de processamento do código é fundamental.

Na Tabela 18 é apresentada a relação entre o número de pontos avaliados em cada um dos escoamentos e o tempo de processamento. Os resultados foram obtidos com processamento em um notebook com CPU IntelCore i5-9400F 2.90Ghz.

Tabela 18. Relação entre o número de pontos e o tempo de cada simulação realizada para o escoamento de suspensão de areia e goma xantana.

<b>Experimento</b>	<b>Número de Pontos Calculados</b>	<b>Tempo Total de Análise [s]</b>	<b>Média de Tempo por Ponto [s]</b>
<b>1</b>	2478	1981	0,8
<b>2</b>	3827	4113	1,1
<b>3</b>	4185	13709	3,3
<b>4</b>	5016	8199	1,6
<b>5</b>	2528	1881	0,7
<b>6</b>	2869	2503	0,9
<b>7</b>	2978	9188	3,1
<b>8</b>	2267	4814	2,1
<b>9</b>	2347	5094	2,2
<b>10</b>	4274	7417	1,7
<b>11</b>	3944	12698	3,2
<b>12</b>	4234	7073	1,7
<b>13</b>	2957	13041	4,4
<b>14</b>	2873	6513	2,3
<b>15</b>	1856	7249	3,9
<b>16</b>	3129	5216	1,7
<b>17</b>	3577	8252	2,3
<b>18</b>	3911	8062	2,1
<b>19</b>	2104	4819	2,3
<b>20</b>	3274	4118	1,2
<b>21</b>	2927	5765	2,0
<b>22</b>	2943	1341	0,5
<b>23</b>	3257	15748	4,8
<b>24</b>	2812	6177	2,2
<b>25</b>	3403	7382	2,2
<b>26</b>	2951	5988	2,0

Fonte: O autor.

O algoritmo apresentou resposta rápida, com médias de tempo por ponto variando de 0,5 até quase 5 segundos por frame avaliado. Vale ressaltar que os vídeos ensaiados têm uma frequência de aquisição de 30 frames por segundo, sendo assim, o caso que apresentou melhor desempenho avaliou um vídeo de 1,5 minutos em 22 minutos e o pior desempenho avaliou um vídeo de 1,8 minutos em 4,3 horas.

Considerando os tempos totais, observa-se que o algoritmo não funcionaria em tempo real, mas algumas modificações podem ser feitas para que o tempo total de análise seja reduzido. Algumas delas serão listadas a seguir e servem como sugestões para trabalhos futuros.

- A primeira modificação seria na quantidade de frames avaliados em cada ensaio. Por mais rápido que seja o escoamento, não são verificadas mudanças significativas que justifiquem a análise de 30 quadros a cada segundo, sendo assim, pode-se avaliar três ou quatro quadros por segundo, o que reduziria em 10 vezes o número de pontos, tornando o código mais rápido.
- Outra modificação é na resolução da imagem. A imagem original retirada do vídeo possui tamanho 1920x1080p, considerada uma imagem em alta resolução. Reduzir o tamanho da imagem pode acelerar o código no sentido de realizar as operações para um número menor de pixels a cada frame.
- A terceira modificação está relacionada à resposta do aplicativo, que foi originalmente desenvolvido para retornar valores de área e velocidade em forma de tabela e em forma de vídeo. Sendo assim, além de ler o frame e realizar todo o processamento de dados, o código ainda cria, a cada frame, imagens que ilustram a área detectada de sólidos e os pontos de correspondência para cálculo da velocidade, salvando-as em dois vídeos para análise posterior. Essa aplicabilidade pode ser útil para o operador, que visualizará a resposta do aplicativo, ainda que não tenha conhecimento de quais valores indicam parâmetros normais e de erro. Entretanto, esta etapa é responsável pelo aumento do custo computacional. Logo, ao retirar os passos de criação desses vídeos, certamente haverá redução no tempo de processamento.

## 8 CONCLUSÕES

De acordo com os resultados apresentados, os aplicativos mostraram grande potencial de adaptabilidade para monitoramento e classificação de diversos tipos de material. A lógica adotada no desenvolvimento deste trabalho possibilitou grande aprendizado em relação às técnicas aplicadas na metodologia. Além disso, a evolução do algoritmo no tratamento dos grupos de sólidos permitiu que as variáveis de interferência, que poderiam comprometer o bom funcionamento do código, fossem identificadas na medida em que a complexidade da análise aumentava.

Os resultados obtidos com o Grupo I foram de grande importância porque, além de validar a unidade experimental montado no LEF/UFRRJ, serviram como prova de conceito de que é possível criar um sistema de monitoramento e classificação de sólidos que funcione somente a partir de vídeos de escoamento. Essa análise foi fundamental para a sequência do estudo, porque incluiu todo o desenvolvimento de um código-mãe que abordasse os conceitos de inteligência artificial tratados nesse trabalho. Foi desenvolvido um aplicativo capaz de estimar algumas propriedades geométricas baseadas em unidades do mundo real e classificar tipos de sólido em escoamento, inclusive em misturas, com alta acurácia, 100%.

O resultado obtido com o Grupo II foi um divisor de águas em se tratando de técnicas de processamento de imagens. Depois de uma unidade experimental validada e metodologia de ensaio definida, foi possível fazer com que as simulações se tornassem mais próximas da realidade dos cascalhos em peneiras reais. Os desafios em relação a detecção de objetos sem formato definido e com maior dificuldade de diferenciação em relação ao plano de fundo foram enfrentados com êxito. Além disso, as modificações realizadas no código-mãe forneceram resultados de detecção animadores em vídeos de peneiras reais.

O estudo feito com o Grupo III aprofundou a análise com fragmentos de rocha, verificando o desempenho do aplicativo quando exposto a tipos de rocha diferentes. De fato, os resultados sugeriram que as análises poderiam se aplicar não somente a materiais diferentes, mas em tamanhos variados, abrindo possibilidade para criação de outras estimativas funcionais. Outra meta alcançada com este grupo de sólidos foi o desenvolvimento e validação das estimativas de maior importância para este trabalho: área preenchida por sólidos (%AP) e velocidade de escoamento. A %AP apresentou desvios menores do que 5%, o que sugere que as técnicas de processamento de imagem, incluindo segmentação, foram adequadas para os vídeos fornecidos. A velocidade do trecho final da calha, cenário de maior interesse, apresentou bons resultados com os detectores MSER, Harris e SURF, onde os desvios foram menores que 10% em relação a velocidade real medida para o mesmo trecho. Isso significa que o ajuste do código-mãe conseguiu minimizar a maioria dos ruídos oriundos da vibração e iluminação, fornecendo um aplicativo com potencial de implementação, apesar das limitações. A vazão de escoamento, ponto chave do estudo realizado, não pôde ser estimada quantitativamente, entretanto, outras técnicas foram testadas alternativamente. Receberam destaque especial as características texturais de Haralick homogeneidade e contraste, que exibiram, com dados normalizados, o mesmo comportamento da curva de %AP, sugerindo que podem estar qualitativamente relacionadas com a vazão. Isso mostra que mesmo que a validação experimental da vazão não tenha sido realizada, é possível pelo menos estimar o seu comportamento qualitativo ao longo do tempo a partir de métodos diferentes.

Todos os ajustes realizados no Grupo III geraram o código utilizado pelo Grupo IV, com cascalhos reais, mais uma vez ratificando as boas técnicas de detecção e processamento. Não foram necessárias alterações na parte do código que avalia o escoamento, já que os resultados foram equivalentes aos do grupo anterior, mas as etapas de classificação foram mais bem exploradas. Novos descritores foram calculados e novas propriedades estatísticas forneceram resultados que podem ser aplicados no controle de estabilidade do processo de perfuração, caso o sistema seja implementado. Pode-se dizer que a aplicação é promissora, ainda que sejam necessários ajustes e inclusão de mecanismos de controle e alerta.

Por fim, a análise do Grupo V trouxe outros desafios, aproximando mais ainda as situações simuladas da realidade do processo de perfuração de petróleo em sonda. A inclusão desse grupo permitiu a identificação de limitações não detectadas em escoamento de material seco e possibilitou ajustes no código-mãe de forma a aumentar a aplicabilidade do código. Ainda faltam muitas etapas para que o aplicativo possa ser implementado em sonda, principalmente em relação ao processamento em tempo real, entretanto, os resultados apresentados nesta dissertação sugerem ser possível alcançar esse objetivo.

## 9 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros têm-se:

- Avaliação da capacidade de detecção do aplicativo em relação ao tamanho para identificar fragmentos de rocha de aspecto seco muito maiores comparado aos outros fragmentos em escoamento, o que indicaria possível instabilidade na perfuração do poço;
- Melhorias na velocidade de processamento do código para implementação de medições em tempo real;
- Desenvolvimento de interface gráfica que facilite a visualização dos resultados e emita mensagens de alerta ao usuário;
- Avaliação de escoamentos em via úmida com outros materiais com coloração variada, como suspensões padronizadas e lama de perfuração real, para avaliar e melhorar o desempenho do software;
- Avaliação do potencial de classificação dos cascalhos quanto ao tipo de solo/profundidade a partir de resultados de análises de DRX;
- Avaliação de cascalhos em condições de peneiras reais, não mais em simulações, e adaptação do código para realidade das peneiras industriais;
- Adaptação para análise simultânea de duas ou três regiões diferentes, para o caso de peneiras com decks duplo e triplo;
- Inclusão de parâmetros de instabilidade, com vídeos que explicitem diversas situações possíveis e as correlacionem com os respectivos problemas para a construção de um sistema de alerta de riscos.

## 10 REFERÊNCIAS BIBLIOGRÁFICAS

ALEXANDRE, E. B.; LOPES, M. D.; RATEKE, T.; CHIARELLA, V. F.; SOBIERANSKI, A. C.; COMUNELLO, E. WANGENHEIM, A. V. Controle de aeromodelo empregando visão computacional. *Computer on the Beach – Artigos Completos*, p. 128 – 137, 2013.

ALMEIDA NETO, J. B. Aproveitamento do cascalho de perfuração de poços para elaboração de pasta de cimentação primária. Tese (Doutorado em Desenvolvimento e Meio Ambiente) – Universidade Federal de Sergipe, p. 139, 2017.

(ALMEIDA, 2018)

ALMEIDA, D. O. Métodos de visão computacional aplicados a extração de características de ambientes urbanos em imagens de satélites de baixa resolução. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Goiás, Goiânia, p. 84, 2018.

(ALMEIDA, 2018<sup>2</sup>)

ALMEIDA, P. H. S. Avaliação de métodos de mosaico de imagens aplicados em imagens agrícolas obtidas por meio de RPA. Dissertação de Mestrado – Computação para Tecnologias Agrícolas, Universidade Estadual de Ponta Grossa. Ponta Grossa – RS, p.68, 2018.

ANP. A história do petróleo no Brasil. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. Jun. 2019,

Disponível em: <http://www.anp.gov.br/institucional/a-historia-do-petroleo>.

Acesso em: 24/09/2019.

ANWAR, A. Diferença entre AlexNet, VGGNet, ResNet e Inception. Medium Corporation. Conteúdo digital publicado em 07/06/2019. Acesso em: 11/07/2020.

Disponível em: <https://towardsdatascience.com/the-w3h-of-alexnet-vggnet-resnet-and-inception-7baaecccc96>

ARAÚJO, G. S.; BICALHO, K. V.; TRISTÃO, F. A. Análise de imagens na determinação da forma e textura de areias. *Revista Brasileira de Ciência do Solo*, v. 39, p. 94 – 99, out. 2015.

BACKES, J. A.; Introdução a Visão Computacional usando Matlab©. Rio de Janeiro: Alta Books, 2016.

BALLARD, D.H.; BROWN, C.M.; *Computer Vision*. Englewood Cliffs, New Jersey 07632, Prentice-Hall, Inc ., 1982. ISBN 0-13-165316-4.

BARANAUSKAS, J. A. Técnicas de clustering (agrupamento). Notas de Aula do Departamento de Física e Matemática da Universidade de São Paulo (USP). 2020.

BARBOSA, V. P. Avaliação de fatores operacionais em processo de peneiramento vibratório aplicado à separação sólido-líquido com o auxílio de técnicas de análise de imagens. Dissertação (Mestrado em Engenharia Química) – Universidade Federal de Uberlândia. Uberlândia, MG, p.99, 2018

BARROS, L. C.; VALENÇA, L. M. M.; MANSO, V. A. V.; MADRUGA FILHO, J. D.; OLIVEIRA, J. A. R. Textura, composição e arredondamento dos sedimentos da plataforma continental interna adjacente às desembocaduras sul do canal de Santa Cruz e do Rio Timbó, norte do estado de Pernambuco. *Estudos Geológicos*, v. 17, 2007.

BATISTA, M.L.S.; CONCI, A.; MOTTA, L.; LIMA, S.M.B.; QUINTÃO, P.L.; Processamento digital de imagens para a detecção e classificação de nódulos em mamografias. *Revista Eletrônica da Faculdade Metodista Granbery*, p. 15, 2010.

Disponível em: <http://re.granbery.edu.br/artigos/Mzk1>. Acesso em: 29/01/2019

BAUERMAN, G.C.; Uso de imagens de sensores remotos na estimativa de características dendométricas de povoamentos de eucalipto. *Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria*, p. 78, 2008.

BRAZ JUNIOR, G. Feature Description SIFT and SURF. *Notas de Aula da Universidade Federal do Maranhão – MA*. 2009.

BORBA FILHO, S. S. Pulverização de plantas daninhas em tempo real utilizando visão computacional. *Trabalho de Conclusão de Curso (Graduação em Engenharia Agrícola e Ambiental) – Instituto de Ciências Agrárias e Tecnológicas da Universidade Federal do Mato Grosso. Rondonópolis*, p. 31, 2019.

CARDOSO JÚNIOR, J. V. L.: Diagnóstico de problemas em poços direcionais durante as manobras. *Dissertação (Mestrado em Engenharia de Petróleo) – Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas. São Paulo*, p. 90, 1992.

CASTAÑÓN, C. A. B. Recuperação de imagens por conteúdo através de análise multirresolução por Wavelets. *Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) – Universidade de São Paulo. São Carlos, SP*, p. 112, 2003.

CESAR, T. M. Uso da transformada de wavelet para análise dinâmica de um sistema fotovoltaico conectado à rede e sua interação com a rede elétrica. *Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Goiás. Goiânia, GO*, p. 96, mar 2018.

CHIPINDU, N. S. C. Pós-análise em problemas de perfuração de poços marítimos de desenvolvimento. *Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas. São Paulo*, p.124, 2010.

CIPELLI, C. A. P.; ASSIS, W. O.; MATTA, E. N.; GOMES, M. M.; GEDRAITE, R. Desenvolvimento de um sistema de captura, processamento e identificação de imagens usando LabView. *14º Congresso Nacional de Iniciação Científica CONIC SEMESP, Centro Universitário do Instituto Mauá de Tecnologia – SP*, 2014.

CONCI, A. Reconhecimento de Padrões: Texturas. *Notas de Aula de Análise de Imagens, Instituto da Computação da Universidade Federal Fluminense (UFF). Niterói – RJ*, 2015.

COSTA, C.A.R.; Introdução ao Processamento Digital de Imagens – Uma abordagem voltada para o sensoriamento remoto e funcionalidades do Sistema Spring. Relatório Técnico, Embrapa – CNPTIA, p. 45, 1998. ISSN 1414-4727.

COSTA, J. M. P. Análise de imagem: medição de área edificada. Trabalho de Conclusão de Curso (Graduação em Engenharia Informática – Licenciatura) – Universidade da Beira Interior. Covilhã – Portugal, p.80, 2010.

DA SILVA, A. O. M.; Perfuração e completção de poços HPHT. Monografia (Engenharia de Petróleo) – Universidade Federal Fluminense. Rio de Janeiro, p. 74, 2016.

ESQUEF, I.A.; ALBUQUERQUE, M.P.; ALBUQUERQUE, M.P.; Processamento Digital de Imagens. Centro Brasileiro de Pesquisas Físicas – CBPF, 2003. Disponível em: <http://www.cbpf.br/cat/pdsi/pdf/cap3webfinal.pdf>. Acesso em: 16/01/2019.

FACCO, P.; SANTOMASO, A. C.; BAROLO, M. Artificial vision system for particle size characterization from bulk materials. Chemical Engineering Science, v. 164, p. 246 – 257, jun. 2017.

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.

FALCÃO, J. L.; POIATE Jr., E.; COSTA, A. M.; ALVES, I. A. S.; ESTON, S. M.: Perfuração em formações salinas. Boletim técnico de produção de Petróleo. Rio de Janeiro, v. 2, n. 2, p. 261 – 286, dez. 2007.

FARIA, E. L. Redes neurais convolucionais em máquinas de aprendizado extremo aplicadas ao mercado financeiro brasileiro. Tese (Doutorado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil da COPPE. Universidade Federal do Rio de Janeiro (UFRJ). Rio de Janeiro – RJ, p.147, 2018.

FLORINDO, J. B. Tópico 10 – Redes Neurais Convolucionais – Deep Learning. Notas de Aula. Instituto de Matemática, Estatística e Computação Científica da Universidade Estadual de Campinas. 2018.

FONSECA NETO, J. Aplicação da Transformada de Fourier no processamento digital de imagens. Aracaju – SE, 1999

FRICK, M. A. D. Caracterização de Minério de Ferro por visão computacional. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria. Santa Maria, RS, p. 61, 2008.

GABOARDI, C. Generalização e análise multirresolução de modelos digitais do terreno com base em transformadas de wavelet. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra da Universidade Federal do Paraná. Curitiba, PR, p. 158, ago 2009.

GALLON, L. Sistema de Visão Computacional para classificação de pedras naturais através de vídeo em tempo real. Trabalho de Conclusão de Curso (Graduação em Sistemas de

Informação) – Centro de Tecnologia da Informação do Centro Universitário UNIVATES. Lajeado, p. 72, 2013.

GOMES, O. F. M. Processamento e análise de imagens aplicados à caracterização automática de materiais. Dissertação (Mestrado em Ciências da Engenharia Metalúrgica) – Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p.151, 2001.

GONÇALVES, L. A. Um estudo sobre a Transformada Rápida de Fourier e seu uso em processamento de imagens. Dissertação (Mestrado em Matemática Aplicada) – Universidade Federal do Rio Grande do Sul. Porto Alegre – RS, p.67, 2004.

GONÇALVES, L. B. Sistema inteligente de classificação de imagens de rochas macroscópicas para a indústria de petróleo e gás. Tese (Doutorado em Engenharia Mecânica) – Programa Francisco Eduardo Mourão Saboya de Pós-Graduação da Universidade Federal Fluminense. Niterói – RJ, p. 309, 2010.

GUILHERME, I. R.; MARANA, A. N.; PAPA, J. P.; CHIACHIA, G.; FALCÃO, A. X.; MIURA, K.; FERREIRA, M. V. D.; TORRES, F. Fast Petroleum Well Drilling Monitoring Through Optimum-Path Forest. *Journal of Next Generation Information Technology*, v. 1, n. 1, p. 77 – 85, dec. 2010.

GUILHERME, I. R.; MARANA, A. N.; PAPA, J. P.; CHIACHIA, G.; AFONSO, L. C. S.; MIURA, K.; FERREIRA, M. V. D.; TORRES, F. Petroleum well drilling monitoring through cutting image analysis and artificial intelligence techniques. *Engineering Applications of Artificial Intelligence* 24, Elsevier, p. 201 – 207, feb. 2011.

GUTIERREZ, C. E. C. Eliminação do ruído por encolhimento de wavelets. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Sistemas de Energia Elétrica da PUC-Rio. Rio de Janeiro, RJ, p. 112, ago 2002.

GROSSI, C. D. Modelagem com redes neurais para predição do crescimento microbiano em reator batelada. Trabalho de Conclusão de Curso (Graduação em Engenharia Química) – Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, p. 94, 2017.

GUYOT, O.; MONREDON, T. LaROSA, D.; BROUSSAUD, A. VisioRock, an integrated vision technology for advanced control of comminution circuits. *Minerals Engineering*, v. 17, p, 1227 – 1235, dec. 2004.

HAMZELOO, E.; MASSINAEI, M.; MEHRSHAD, N. Estimation of particle size distribution on an industrial conveyor belt using image analysis and neural network. *Powder Technology*, v. 261, Elsevier, p. 185 – 190, jul. 2014.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *Institute of Electrical and Electronics Engineers. IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, n. 6, p610-621, nov., 1973.

HAWLITSCHKE, G.; ULSEN, C.; KAHN, H.; MASINI, E. A.; TOCCHINI, M. Análise de imagens dinâmica - caracterização da distribuição de tamanho e forma de partículas. *Holos*, v. 3, Ano 31, p. 22 – 29, mai. 2015.

HORTA, E. G. Aplicação de máquinas de aprendizado extremo ao problema de aprendizado ativo. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Minas Gerais. Belo Horizonte, p. 100, 2015.

IDAGAWA, L. S.: Diagnóstico de Problemas de Poços Direcionais. Dissertação (Mestrado em Engenharia de Petróleo) – Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas. São Paulo, p. 201, 1990.

(IMAGENET<sup>1</sup> – Stanford). Banco de imagens *ImageNet*.

Disponível em: <http://imagenet.stanford.edu/about-overview>

Acesso em: 15/07/2020.

(IMAGENET<sup>2</sup> – Stanford). ImageNet Large Scale Visual Recognition Challenge.

Disponível em: <http://www.image-net.org/challenges/LSVRC/>

Acesso em: 15/07/2020.

JESUS, S. R. Análise de desempenho de detectores e descritores de características utilizando a plataforma computacional Raspberry PI. Trabalho de Conclusão de Curso (Graduação em Ciências Exatas e Tecnológicas) – Universidade Federal do Recôncavo da Bahia. Cruz das Almas – BA, p.61, 2019.

JESUS, S. R.; ROCHA, W. C. J.; BITTENCOURT, J. C. N. Análise de desempenho de detectores e descritores de características utilizando a plataforma computacional Raspberry Pi. Anais da XIX Escola Regional de Computação – Bahia, Alagoas e Sergipe, p. 372-381, 2020.

JIANG, M. Mathematical models in computer vision and image processing. Department of Information Science, School of Mathematics, Peking University. Ed.: Springer, p. 148, 2001.

JURASZEK, G. F. Reconhecimento de produtos por imagem utilizando palavras visuais e redes neurais convolucionais. Dissertação (Mestrado em Computação Aplicada) – Universidade do Estado de Santa Catarina. Joinville – SC, p.155, 2014.

KARIMI, M. Drill-Cuttings analysis for real-time problem diagnosis and drilling performance optimization. Weatherford, Society of Petroleum Engineers, SPE Asia Pacific Oil & Gas Conference, 165919, Jakarta, Indonesia, p. 22 – 24, oct. 2013.

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, jan. 2015.

KHORRAM, F.; MERMARIAN, H.; TOKHMECHI, B.; SOLTANIAN-ZADEH, H. Limestone chemical components estimation using image processing and pattern recognition techniques. Journal of Mining & Environment 2, v. 2, p. 126 – 135, dec. 2011.

KISTNER, M.; JEMWA, G. T.; ALDRICH, C. Monitoring of mineral processing systems by using textural image analysis. Minerals Engineering, v. 52, Elsevier, p. 169 – 177, oct. 2013.

KO Y.D.; SHANG, H. A neural network-based soft sensor for particle size distribution using image analysis. *Powder Technology*, v. 212, Elsevier, p. 359 – 366, oct. 2011.

LECUN, Y., BOTTOU, L., BENGIO, Y. & HAFFNER, P. Aprendizagem baseada em gradiente aplicada ao reconhecimento de documentos. *Proc. IEEE* **86**, 2278-2324 (1998).

LECUN, Y., BENGIO, Y. & HINTON, G. *Deep Learning*. *Nature* **521**, 436-444 (2015).

LIAO, C.-W.; YU, J.-H.; TARNG, Y.-S. On-line full scan inspection of particle size and shape using digital image processing. *Particuology*, v. 8, Elsevier, p. 286 – 292, jun. 2010.

LIMA, R. P. S.; CARVALHO, C. S. S. Implantação de um sistema de visão computacional aplicada ao controle de qualidade de agulhas em uma indústria farmacêutica. Trabalho de Conclusão de Curso – Universidade Tecnológica Federal do Paraná. Curitiba - PR, p.51, 2014.

MACEDO, S. O. Desenvolvimento de um sistema de auxílio ao diagnóstico de pneumonia na infância utilizando visão computacional. Dissertação (Mestrado em Ciências Exatas e da Terra - Ciências da Computação) - Universidade Federal de Goiás, Goiânia, p. 50, 2012.

MALHEIROS, L. Detecção de posição e quedas corporais baseado em k-means clustering e threshold. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Tecnologia da Universidade de Brasília. Brasília, p.77, 2017.

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, aug. 2009.

MARQUES, A. C. R. Contribuição à abordagem de problemas de classificação por redes convolucionais profundas. Tese (Doutorado em Engenharia Elétrica com Ênfase em Automação) – Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas. Campinas – SP, p.121, 2018.

MARTINS, F. P. R. Calibração de padrões metrológicos utilizando visão computacional. Universidade de São Paulo. Tese. São Paulo, 1999.

MARTINS, J. G. Identificação de espécies florestais utilizando seleção dinâmica de classificadores no espaço de dissimilaridade. Tese (Doutorado em Ciência da Computação) – Setor de Ciências Exatas da Universidade Federal do Paraná. Curitiba, p.160, 2014.

MATHIAS, V. M. Coluna de perfuração em poços de petróleo. Monografia (Engenharia de Petróleo) – Universidade Federal do Rio Grande do Norte. Natal, p. 53, 2016.

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, p.95, 2014.

(MATTA et al., 2014)1

MATTA, E. N.; MARANHÃO, G. F. G.; ORTIZ, R. S. L.; ASSIS, W. O.; GEDRAITE, R.; COELHO, A. D.; KUNIGK, L. Caracterização de partículas em fluido utilizado na perfuração de poços de petróleo. Anais do XX Congresso Brasileiro de Automática, Belo Horizonte – MG, 2014.

(MATTA et al., 2014)2

MATTA, E. N.; CIPELLI, C. A. P.; GOMES, M. M.; GUERREIRO, F. S.; GEDRAITE, R.; KUNIGK, L.; ASSIS, W. O. Contribuição ao estudo do comportamento de peneira vibratória tipicamente empregada em unidade de tratamento de fluido de perfuração. Anais do XX Congresso Brasileiro de Engenharia Química, Florianópolis – SC, 2014.

MATTA, E. N.; GEDRAITE, R.; KUNIGK, L.; ASSIS, W. O. Utilização de sistema de visão computacional para monitoração de protótipo de peneira vibratória. VI Encontro Nacional de Hidráulica de Poços de Petróleo e Gás, Rio Quente – GO, 2015.

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 – 3659, Curitiba – SC, 2019.

MBP COPPE. História do Petróleo. Universidade Federal do Rio de Janeiro, Rio de Janeiro – RJ, fev. 2014.

Disponível em: <http://petroleo.coppe.ufrj.br/historia-do-petroleo/>

Acesso em 24/09/2019.

MILLER, N. A.; HENDERSON, J. J. Quantifying Sand Particle Shape Complexity using a Dynamic Imaging Technique. Agronomy Journal, v. 102, n. 5, p. 1407 – 1414, sep. 2010.

MONTANARI, R. Detecção e classificação de objetos em imagens para rastreamento de veículos. Dissertação (Mestrado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação da USP (ICMC – USP). São Carlos – SP, p.81, 2015.

NAJARIAN, K.; SPLINTER, R. Biomedical Signal and Image Processing. CRC Press – Taylor & Francis Group. Curso PISB 2017.2, p.92, 2006

NASCIMENTO, J. P. R. Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência. Dissertação (Mestrado em Informática) – Setor de Ciências Exatas da Universidade Federal do Paraná. Curitiba – PR, p. 116, 2003.

NOVAIS, J. P. Aplicação dos Algoritmos SIFT e SURF na classificação de sub-imagens por discriminação de textura. Trabalho de Conclusão de Curso ( Graduação em Ciência da Computação) – Centro Universitário Eurípides de Marília, Marília, p.105, 2016

OLIVEIRA, W. E. B.; PRADO, A. F.; FERNANDES, S. R.; FACEROLI, S. T. Classificação de padrões utilizando descritores de textura. XI Simpósio de Mecânica Computacional / II Encontro Mineiro de Modelagem Computacional. Juiz de Fora – MG, mai. 2014.

OLIVEIRA, W. R. Sistema de Visão Computacional para reconhecimento de modelos CAD complexos. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Universidade Federal de Pernambuco. Recife – PE, p.45, 2018.

OLIVEIRA FILHO, K. S. Fundamentos de Radiodiagnóstico por imagem. Instituto de Física da UFRGS, 1999. Conteúdo Digital:

<http://astro.if.ufrgs.br/med/imagens/node41.htm>

<http://astro.if.ufrgs.br/med/imagens/node42.htm>

ORDOÑEZ, M.F.C. Efeito do empacotamento de partículas nas propriedades mecânicas e tribológicas de misturar de argila-rocha. Dissertação (Mestrado em Ciências e Engenharia de Materiais) – Universidade de Caxias do Sul. Caxias do Sul, p. 136, 2015.

ORTIZ NETO, J. B. ; COSTA, A. J. D. A Petrobrás e a exploração de petróleo offshore no Brasil: um approach evolucionário. (2007) Revista Brasileira de Economia, v. 61, n. 1, p. 95 – 109, mar. 2007.

PAGAMISSE, A.; Discriminação de Texturas pela transformada de wavelet. Tese (Doutorado em Matemática Aplicada) – Instituto de Matemática, Estatística e Computação Científica da Universidade Estadual de Campinas, Campinas, p. 122, 2004

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.

PEREIRA, D. B. Análise e implementação de sistemas para detecção de placas brasileiras de sinalização de trânsito. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Universidade Federal de Santa Catarina. Araranguá – SC, p. 95, 2018.

PETRI JÚNIOR, 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.

PRATI, R. C. Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos. Tese (Doutorado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo. São Paulo, p. 191, 2006.

PUPIN, J.R. Introdução às Séries e Transformadas de Fourier e aplicações no processamento de sinais e imagens. Trabalho de Conclusão de Curso – Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos. São Carlos – SP, p. 82, 2011.

QUEIROZ, J.E.R.; GOMES, H.M.; Introdução ao Processamento Digital de Imagens.

Revista RITA, vol. VIII, n.1. Departamento de Sistemas e Computação da Universidade Federal de Campina Grande. Campina Grande – PB, p.31, 2001.

RABINSKI, G; THOMAS, D. Dynamic digital image analysis: emerging technology for particle characterization. *Water Science and Technology*, v. 50, n. 12, p. 19 – 26, dec. 2004.

RIBEIRO, S.; BONETTI, C. Variabilidade morfométrica de sedimentos arenosos: revisão de métodos e uso do software ImageJ na diferenciação de ambientes deposicionais da ilha de Santa Catarina e região Continental. *Porto Alegre, Gravel*, v. 11, n. 1, p. 37 – 47, dez., 2013.

RODENACKER, K; BENGTSSON, E.; A feature set for cytometry on digitized microscopic images. *Analytical Cellular Pathology*, v. 25, p. 1 – 36, 2003.

RONCERO, V. G. Um estudo de segmentação de imagens baseado em um método de computação evolucionária. *Dissertação (Mestrado em Ciências em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro*, p. 80, 2005.

SALDANHA, M. F.; FREITAS, C. Segmentação de imagens digitais: Uma revisão. *Divisão de Processamento de Imagens – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos*, 2009.

SANCHES, C.H; FONTOURA, P.J.; VIEIRA, P.F.; BATISTA, M.A.; Técnicas de Suavização de Imagens e Eliminação de Ruídos. *EATI – Encontro Anual de Tecnologia da Informação*, 2015, Rio Grande do Sul. p. 21-30.

SANTIAGO, T. S. A.; BARBOSA, V. P.; GEDRAITE, R.; ATAÍDE, C. H. Análise de imagem aplicada ao processo de separação sólido – líquido em peneira vibratória no processo de perfuração de poços de petróleo. *XII Congresso Brasileiro de Engenharia Química em Iniciação Científica, Universidade Federal de São Carlos. São Paulo*, jul. 2017.

SANSONE, E. C. Porosidade das Rochas. *Notas de aula (Disciplina Mecânica de Fluidos Aplicada a Reservatórios) – Escola Politécnica da Universidade de São Paulo. São Paulo*, p. 53, 2014.

SCHWARTZ, W.R.; PEDRINI, H.; Método para classificação de imagens baseada em matrizes de co-ocorrência utilizando características de textura. *Anais do III Colóquio Brasileiro de Ciências Geodésicas*, 2003.

SCURI, A.E.; *Fundamentos da Imagem Digital. TECGRAF – PUC-Rio*, 1999. Disponível em: <https://dcce4f40-a-62cb3a1a-s-sites.googlegroups.com/site/gcamarac/bcc-326---processamento-de-imagens/apostila20imagem20digital.pdf>. Acesso em 09/01/2019.

SERAPIÃO, A. B. S.; MENDES, J. R. P.; MIURA, K. Sistema de visão computacional para detecção de cascalho de perfuração em poços de petróleo. *Anais do 6º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás (PDPetro), Florianópolis – SC*, 2011.

SILVA, C.Y.V.W.; Extração de características de imagens médicas utilizando wavelets para mineração de imagens e auxílio ao diagnóstico. *Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e da Computação da Universidade de São Paulo, São Paulo*, p. 123, 2007.

SILVA, F. A.; PAIVA, M. S. V.; ARTERO, A. O.; PITERI, M. A. Evaluation of keypoint detectors and descriptors. IX Workshop de Visão Computacional, Rio de Janeiro - RJ. ISSN 2526-5997. Anais 2013.

SILVA, J. J. Combinação de Classificadores Floresta de Caminhos Ótimos Aplicados no Reconhecimento Facial. Dissertação (Mestrado em Ciência da Computação) – Faculdade Campo Limpo Paulista, Campo Limpo Paulista, p. 101, 2016.

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.

SILVA, J. M. P. L. Aplicação da transformada de wavelet packet e redes neurais artificiais para monitoramento de condição de motores de indução. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Pernambuco. Recife, PE, p. 150, ago 2017

SOUSA, M. C. F. Método para execução de redes neurais convolucionais em FPGA. Dissertação (Mestrado em Ciência Microeletrônica) – Escola Politécnica da Universidade de São Paulo (USP). São Paulo – SP, p. 115, 2019.

SOUTO JUNIOR, C.A.; Avaliação de descritores de textura para segmentação não supervisionada de imagens. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, Campinas, p. 128, 2010.

SOUZA, G. B.; MARANA, A. N. Reconhecimento de Pessoas em Imagens de Vídeo utilizando características biométricas leves. VI Workshop de Visão Computacional, Universidade Estadual Paulista (UNESP). P. 84 – 89, jul. 2004.

SOUZA, V. C. O. Análise computacional de padrões estruturais não-lineares a partir de imagens digitais com estudos de caso em ciências ambientais e espaciais. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais (INPE). São José dos Campos – SP, p.191, 2017.

SRIVIDHYA, S.; PRAKASH, S. Performance Evaluation of various features detection algorithms in VSLAM. Indian Journal of Research – PARIPEX, v.6, Issue:2 ISSN – 2250-1991. P. 386-388, Feb, 2017.

STOLFI, G.; Vídeo Digital. Capítulo 3: Princípios de Televisão Digital – Escola Politécnica da Universidade de São Paulo – USP, 2008.  
Disponível em: [http://www.lcs.poli.usp.br/~gstolfi/mack/Ap3\\_VideoDigital\\_M8.pdf](http://www.lcs.poli.usp.br/~gstolfi/mack/Ap3_VideoDigital_M8.pdf) .  
Acesso em: 26/01/2019

TAKEMURA, C.M.; DRUCKER, D.P.; Processamento de Imagens Digitais e Gestão da Informação. Embrapa Territorial, cap. 5, CNPTIA, p. 80 – 91, 2014.

TAVARES, R. M. Interpretação e análise de dados de perfuração em poços de petróleo. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia

Mecânica e Instituto de Geociências, Universidade Estadual de Campinas. São Paulo, p.145, 2006.

TIAN, K.; Li, J.; ZENG, J.; EVANS, A. ZHANG, L. Segmentation of tomato leaf images based on adaptive clustering number of k-means algorithm. Computers and Electronics in Agriculture, v. 165, ago – 2019.

TOROK, Leonardo. Método de Otsu. Instituto da Computação – Universidade Federal Fluminense, Niterói – RJ. 2015.

VALE, G.M.; POZ, A. P. D. Processo de detecção de bordas de Canny. Boletim de Ciências Geodésias, sec. – UNESP. Artigos, Curitiba, v.8, nº2, p.67-78, 2002.

VERMA, S.B.; CHANDRAN, S. Comparative study of FAST, MSER, and Harris for palmprint verification system. International Journal of Scientific & Engineering Research, v. 7, n. 12, dec – 2016.

VICTORIANO, E.R.S.; SANTOS, D.O.; MACIEL, R.; Reconhecimento de Imagens através da visão de máquina. AEDB – Associação Educacional Dom Bosco, 2015.

YAGHOOBI, H.; MANSOURI, H.; FARSANGI, M. A. E.; NEZAMABADI-POUR, H. Determining the fragmented rock size distribution using textural feature extraction of images. Powder Technology, v. 342, p. 630 – 641, jan. 2019.

YANG, J.; CHEN, S. An online detection system for aggregate sizes and shapes based on digital image processing. Mineralogy and Petrology, v. 111, p. 135 – 144, feb. 2017.

YU, W.; HANCOCK, B. C. Evaluation of dynamic image analysis for characterizing pharmaceutical excipient particles. International Journal of Pharmaceutics, v. 361, p. 150 – 157, sep. 2008.

ZACARKIM, V. L. Avaliação de detector de pontos de interesse IGFTT em visual SLAM. Dissertação (Mestrado em Informática) – Setor de Ciências Exatas da Universidade Federal do Paraná. Curitiba – SC, p.137, 2017.