

## CARACTERIZAÇÃO AUTOMÁTICA DE FRAGMENTOS DE ROCHA EM ESCOAMENTO UTILIZANDO TÉCNICAS DE VISÃO COMPUTACIONAL

CAROLINE D. GROSSI<sup>1,2\*</sup>, YURI N. HUMMEL<sup>2</sup>, EVELYN A. MOURA<sup>2</sup>, MAURÍCIO B. DE SOUZA JR.<sup>1</sup>, CLÁUDIA M. SCHEID<sup>2</sup>, LUÍS A. CALÇADA<sup>2</sup>, LUIZ A. C. MELEIRO<sup>2</sup>

<sup>1</sup>Universidade Federal do Rio de Janeiro, EPQB/UFRJ

<sup>2</sup>Universidade Federal Rural do Rio de Janeiro, IT/DEQ

Laboratório de escoamento de Fluidos Giullio Massarani – LEF/UFRRJ

\*e-mail: cdiasgrossi@ufrj.br

**RESUMO** – A caracterização de material particulado tem aplicação importante em diversos segmentos industriais. O objetivo deste trabalho foi estimar propriedades morfológicas de rochas a partir da análise de imagens dinâmicas e classificar o material em escoamento de acordo com faixas de tamanho. Foram realizados experimentos com fragmentos de mármore, granito, quartzo e cascalho oriundo da perfuração de poços. As ferramentas utilizadas foram Transformada Bidimensional Discreta de Fourier para detecção e posterior estimativa de propriedades de tamanho médio, arredondamento e excentricidade e Redes Neurais Convolucionais para a classificação das faixas de tamanho. Os resultados mostraram que os algoritmos de visão computacional desenvolvidos têm capacidade de realizar boas estimativas e podem ser úteis no monitoramento automático e não invasivo de fragmentos de rochas.

### INTRODUÇÃO

A caracterização de sólidos particulados em processos industriais é uma prática comum, tendo importância em diversos setores industriais. Um exemplo é o controle de qualidade nas indústrias farmacêutica e alimentícia. Outro exemplo aplica-se à indústria química, onde a granulometria e morfologia de diversos particulados pode influenciar na reologia de suspensões ou ainda na eficiência de leitos fluidizados.

Dentro das aplicações na indústria de petróleo, cita-se a análise de cascalho que retorna do poço durante o processo de perfuração. Os fragmentos são coletados, limpos e secos, sendo posteriormente separados por tamanho. Cascalhos considerados graúdos, maiores que o tamanho esperado de acordo com a broca utilizada na perfuração, podem indicar problemas como desmoronamento de poço. Dessa forma, a avaliação de propriedades morfológicas torna-se uma ferramenta

importante na prevenção de acidentes (Fagundes, 2018).

Um procedimento padrão para a avaliação dos cascalhos graúdos é a comparação visual da forma e textura do material coletado com uma cartilha-padrão (Figura 1). Esta análise relaciona aspectos de arredondamento e esfericidade com a porosidade, permeabilidade e empacotamento do solo e com a distância percorrida pela partícula até a superfície. Neste último caso, pode-se especular qual formação rochosa possivelmente está mal consolidada (Matta, 2014; Ordoñez, 2015).

### Caracterização Morfológica por Imagem

Um novo horizonte pôde ser desbravado com a popularização da fotografia digital e o aumento da capacidade de processamento dos computadores. Softwares de análise de imagem ganharam espaço no controle de processos, possibilitando o alcance de estimativas confiáveis em menor tempo (Hawlitshchek *et al.*, 2015).



Figura 1: Relação entre arredondamento, esfericidade e porosidade.

Fonte: Sansone, 2014.

Hawlitschek *et al.* (2013) citam três normas utilizadas na análise granulométrica: ISO13322-1/04, ISO13322-2/06 e NBR7809.

A norma NBR 7809 descreve o procedimento para determinação do índice de forma de agregados graúdos por meio do método do paquímetro. A norma ISO 13322-1/04 utiliza análise de imagens para a determinação da distribuição de tamanho de partículas fixadas em superfície fotografável, a chamada análise de imagens estáticas, abrangendo imagens microscópicas. A norma ISO 13322-2/06 também utiliza análise de imagens para caracterização de particulado, entretanto, define parâmetros para análise de imagens dinâmicas, de materiais em escoamento.

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 para congelar opticamente as partículas enquanto uma câmera de alta resolução captura as projeções. Estas passam por processamento e as características de cada uma das partículas são calculadas. O CAMSIZER utiliza o mesmo princípio, mas com duas fontes de luz pulsada e duas câmeras de alta resolução trabalhando com zoom diferente. A vantagem estatística é 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.

Os equipamentos são muito úteis para a análise granulométrica e morfológica,

entretanto, para a aplicação na caracterização de cascalho, são necessárias amostragens e pré-tratamento, trazendo vantagens apenas na precisão de resposta em relação aos olhos do geólogo analista. Além disso, esses equipamentos fornecem medidas geométricas dos sólidos avaliados sem classificá-los, gerando um banco de dados que precisa ser tratado para fornecer, de maneira aproveitável, uma resposta às condições de perfuração.

Uma questão interessante a ser levantada é que, apesar da boa resposta, esses equipamentos não são capazes de fornecer estimativas em tempo real numa linha de produção, independentemente do setor, eles são aplicáveis a sistemas de controle de qualidade.

Nesse sentido, a proposta deste trabalho foi utilizar o mesmo princípio de análise de imagens dinâmicas, com aplicação de técnicas de visão computacional, para a caracterização de fragmentos de rocha em escoamento como prova de conceito para a aplicação posterior em análise de cascalho de perfuração.

### Visão Computacional

Visão computacional é um segmento da inteligência artificial que tem como finalidade a extração de informações a partir de vídeos ou imagens, possibilitando a automatização e integração de processos. Independentemente do setor, aplicações de visão computacional seguem um algoritmo básico de projeto.

Primeiro é feita a aquisição da imagem digital por uma câmera. O passo seguinte é a etapa de processamento da imagem, abrangendo passos de correção, filtragem e identificação do objeto de interesse. As etapas

de correção podem ser aplicadas com a finalidade de melhorar a qualidade das imagens e restaurar informações perdidas. A essa etapa dá-se o nome de pré-processamento (Ballard & Brown, 1892).

Com a imagem em sua melhor versão, realiza-se a detecção dos objetos de interesse, chamada segmentação. Seu objetivo é a segregação de pixels em regiões, podendo utilizar critérios de similaridade ou de descontinuidade. É a etapa crítica do algoritmo de visão computacional, uma vez que qualquer erro ou distorções são refletidos na etapa seguinte, podendo mascarar o resultado ou torná-lo 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 (Costa, 1998).

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).

Após a detecção dos objetos de interesse, realiza-se a extração das características, que podem ser morfológicas, de maior interesse no presente trabalho, ou texturais. Por fim, a partir das características extraídas, realiza-se o cálculo de estimativas e classificação, etapa diretamente ligada ao processo em análise.

O objetivo deste trabalho foi realizar a detecção de fragmentos de rocha em escoamento, diferenciando-os do plano de fundo, além de estimar algumas propriedades morfológicas e classificá-los em relação a seu tamanho.

A técnica utilizada na detecção aplicou Transformada Bidimensional Discreta de Fourier (DFT-2D) para a identificação das bordas dos fragmentos. A técnica utilizada na classificação das partículas em escoamento aplicou redes neurais convolucionais (CNN), de forma que fosse identificado escoamento de partículas de tamanho esperado ou presença de partículas grandes.

### Transformada Bidimensional Discreta de Fourier

A Transformada de Fourier é uma ferramenta matemática utilizada para transformar o

domínio de funções, variando entre tempo/espço e frequência. Sua aplicabilidade é ampla, já que muitas vezes é preciso analisar a frequência com que um determinado sinal se apresenta, ou seu desvio em relação a um valor de referência, em detrimento da posição ou o tempo em que ele ocorreu (Najarian & Splinter, 2006).

A Transformada Discreta de Fourier (DFT) é obtida a partir da discretização da Série de Fourier que representa o processo estudado e seus coeficientes são estimados com precisão quanto menor for o intervalo de amostragem (PUPIN, 2011). Considerando que o processo estudado é uma imagem digital, formada pela discretização da cena real em uma matriz de intensidades de pixel, pode-se aplicar a Transformada Bidimensional Discreta de Fourier (DFT-2D), para as coordenadas (x,y) do sistema, pelo par da DFT direta em inversa.

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

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

onde  $f(x, y)$  representa a imagem no domínio do tempo/espço; N e M representam o número de linhas e colunas da matriz da imagem, respectivamente; 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  $\Delta w_y = \frac{1}{N \cdot \Delta y}$ ; 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 (Oliveira Filho, 1999).

Pela DFT, qualquer sinal pode ser representado como uma soma de funções seno. Dessa forma, as imagens são representadas pela soma das funções seno que representam a variação de brilho em cada canal. As informações contidas numa imagem senoide 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 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 trasladado e informa onde cada componente de frequência está localizado (Najarian & Splinter, 2006).

A detecção das bordas utilizando o método da transformada de Fourier representa uma operação de filtragem, explicada pelo Teorema da Convolução (TC). O TC define que a convolução entre duas funções no domínio tempo/espaço equivale à 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, também chamado *kernel*, a uma imagem senoide, desde que a ele também seja aplicada a respectiva Transformada de Fourier. Neste trabalho esta técnica teve como finalidade a segmentação, detecção de objetos em uma imagem, então a segunda função senoide será representada por um *kernel* de detecção de contornos.

### Redes Neurais Convolucionais

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

As camadas de convolução, como o nome sugere, são responsáveis pela operação de convolução entre a imagem e o filtro, gerando como resposta um mapa de características. As camadas de *pooling* são aplicadas após as camadas de convolução, tendo como objetivo a redução da dimensionalidade a partir da

preservação dos pixels mais representativos de cada região. A camada completamente conectada é responsável pela classificação.

O treinamento dos módulos é feito separadamente. No módulo de aprendizado geral ocorre 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 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).

O treinamento do módulo de aprendizado específico depende do problema, devendo ser repetido a cada nova abordagem, ou em casos que o banco de dados seja modificado de forma expressiva. Em contrapartida, o treinamento do módulo de aprendizado geral 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).

Neste trabalho foi aplicada a técnica de *transfer learning* utilizando o módulo de aprendizado geral da CNN *AlexNet*.

## METODOLOGIA

A metodologia empregada neste trabalho foi dividida em duas etapas: (i) parte experimental desenvolvida no Laboratório de escoamento de Fluidos Giulio Massarani da

Universidade Federal Rural do Rio de Janeiro (LEF/UFRRJ), que envolveu a construção da unidade experimental e ensaios de escoamento de sólidos variados; (ii) desenvolvimento e validação dos algoritmos de caracterização e classificação de sólidos.

### Unidade Experimental

A unidade experimental, ilustrada na Figura 2, possui um silo de armazenamento de sólidos no formato de pirâmide invertida acoplado a uma calha metálica, por onde o escoamento ocorre. Adjacente ao silo, fixou-se um dosador vibratório, marca MVL Vibradores Industriais LTDA, que varia a intensidade de vibração de 0 a 100%. Ao final da calha, tem-se um reservatório captador de sólidos e, a uma distância de 20cm, foi instalado 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 à calha.



Figura 2: Unidade Experimental.

### Fragmentos de Rocha

Utilizaram-se nas análises fragmentos de mármore, granito, quartzo e cascalho de perfuração (Figura 3). Os sólidos foram submetidos à separação granulométrica com peneiras laboratoriais de aberturas 2,36mm, 1,18mm, 0,60mm, 0,30mm e 0,15mm (Figura 4).

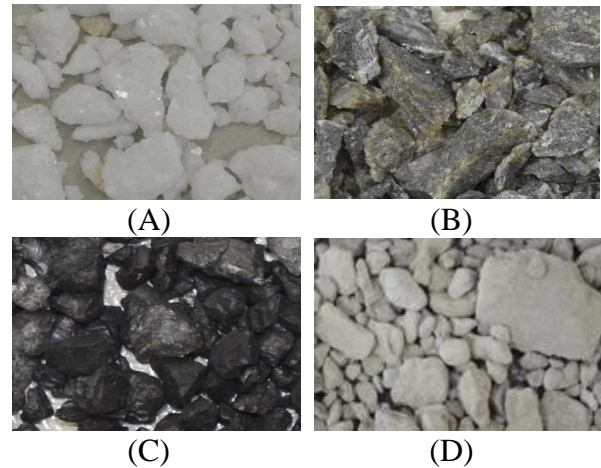


Figura 3: Fotos de fragmentos de (A) mármore, (B) granito, (C) quartzo e (D) cascalho de perfuração.




Figura 4: Fotos de cascalho após separação granulométrica.

### Procedimento Experimental

Antes do início do ensaio foram ajustadas a altura do anteparo de saída de sólidos do silo e a intensidade de vibração. Foram testados valores de 20% a 60% de intensidade.

Os ensaios foram realizados iniciando a vibração e fornecendo, aos poucos, os sólidos ao silo. Todos os escoamentos foram registrados pela câmera. Os vídeos foram posteriormente tratados para obtenção de resultados.

### Aplicativo de Caracterização de Sólidos

A primeira etapa do aplicativo de caracterização é o carregamento do vídeo, que

é separado em frames a uma frequência de 30 frames por segundo, taxa padrão de aquisição de imagens. Cada frame é submetido a uma etapa de pré-processamento (Figura 5) que envolve transformações geométricas e

projetivas de forma a obter um recorte representativo e analisável da vista superior da calha. A imagem pré-tratada foi utilizada como entrada para os algoritmos de segmentação e classificação.




Figura 5: Pré-processamento da imagem de entrada. Fonte: O autor.

### Algoritmo de Segmentação

O objetivo do algoritmo de segmentação é detectar as bordas dos sólidos com a maior precisão possível para que possam ser extraídas características de área, perímetro e diâmetro das partículas identificadas, possibilitando a estimativa de propriedades como tamanho médio de partículas, arredondamento e excentricidade.

O arredondamento (Equação 3) 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 (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. Para muitos casos essa propriedade é substituída pela circularidade, que representa o quanto a projeção de um fragmento no plano bidimensional se aproxima de um círculo (Ordoñez, 2015).

$$\text{Arredondamento} = \frac{4\pi A}{p^2} \quad (3)$$

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

onde  $A$  representa a área da projeção do sólido analisado,  $p$  representa o perímetro e  $L$  o comprimento do maior eixo.

A técnica utilizada neste algoritmo aplicou as etapas de pré-processamento descritas no aplicativo de caracterização de sólidos, DFT-2D, e algumas etapas de pós-processamento até a obtenção da imagem binarizada. O detalhamento das etapas é feito a seguir e o fluxograma de descrição é apresentado na (Figura 6).

Passo 1: converteu-se a imagem pré-processada da etapa anterior em níveis de cinza e definiram-se os filtros de atuação vertical e horizontal utilizados para a detecção de bordas. Como a imagem fornecida ao algoritmo pode não possuir o mesmo tamanho nas duas dimensões, foi preciso encontrar o maior tamanho para que este seja o tamanho do espectro de potência gerado.

Passo 2: aplicou-se DFT-2D direta na imagem e nos dois filtros e a operação de filtragem foi efetuada pela multiplicação ponto a ponto da imagem com cada um dos filtros. Como resposta, obtêm-se duas imagens filtradas, uma como resultado da atuação vertical e outra como resultado da atuação horizontal.

Passo 3: aplicou-se a DFT-2D inversa nas imagens, que retornam ao domínio espacial. As imagens foram combinadas para formar a imagem de saída com as bordas detectadas e

posteriormente binarizadas para detecção dos objetos e cálculo das características. As características morfológicas são calculadas a partir da imagem binarizada utilizando a função *regionprops* do software MatLab©.

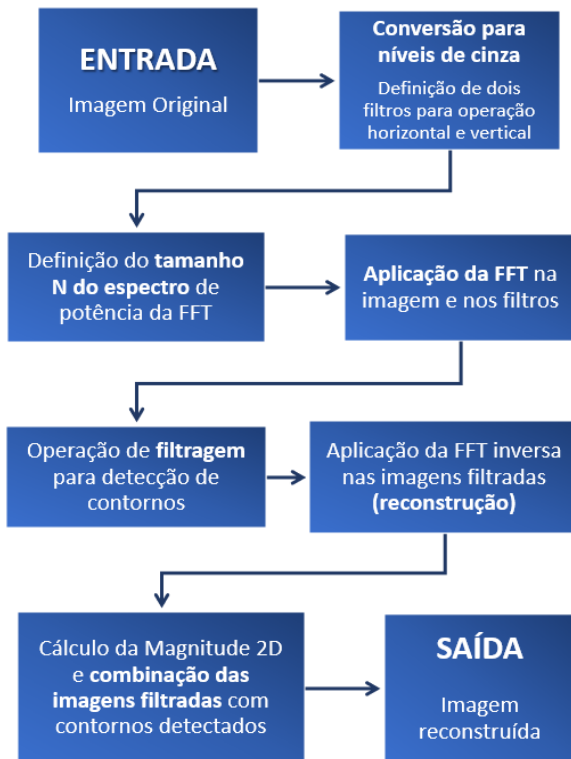


Figura 6: Fluxograma do algoritmo do Método da Transformada de Fourier.

### Aplicativo de Classificação de Sólidos

O objetivo do algoritmo de classificação é identificar, de forma automática e não invasiva, se há partículas de tamanho maior que o esperado presentes no escoamento. Para essa análise, foram avaliados escoamentos de cascalho de perfuração, apenas.

O banco de imagens foi obtido a partir de fotografias dos cascalhos em tamanhos variados. Após a separação granulométrica, cada fração foi disposta em superfície fotografável de forma aleatória, possibilitando a aquisição das imagens.

O aspecto dos cascalhos apresenta certa homogeneidade, considerando características de coloração e textura. Dessa forma, a diferenciação é dificultada. Com isso, utilizou-se uma técnica similar à descrita por Khojasteh *et al.* (2015) para a manipulação do banco de forma a melhorar a capacidade de diferenciação.

Nesta técnica de pré-tratamento do banco de dados, cada imagem passou por um fracionamento, dividindo a imagem original em sub-imagens (Figura 7). Foram testadas duas formatações: (i) tamanho 300x300 pixels, com banco de 6.100 imagens, DS1; e (ii) tamanho 600x600, com banco de 2000 imagens, DS2.

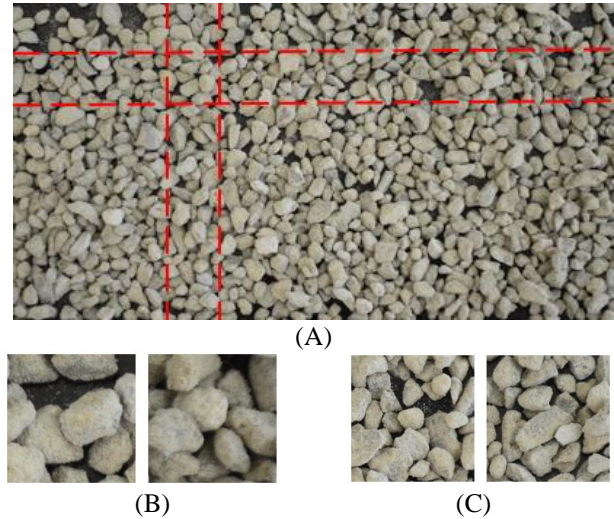


Figura 7: Pré-tratamento do banco de imagens. (A) Técnica de fragmentação. (B) Sub-imagens 300x300. (C) Sub-imagens 600x600.

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

As imagens foram divididas em treinamento, teste e validação na proporção 80%, 10% e 10%, respectivamente. 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. O treinamento foi realizado com o software de apoio MatLab©.

Na etapa de treinamento, a CNN recebeu como entrada a imagem pré-processada e sua respectiva fração de tamanho. O resultado foi apresentado na forma de Matriz Confusão, que exibe os resultados na forma gráfica de classificações corretas versus classificações preditas, onde o número de acertos se concentra na diagonal principal.

## RESULTADOS

Cada um dos materiais foi separado por faixas de tamanho, conforme descrito na Metodologia, e a representação dessa diferença pode ser vista na Figura 8. O objetivo da separação foi avaliar a capacidade de classificação do software quanto ao tamanho, prevendo a posterior implementação de um sistema de monitoramento capaz de identificar o tamanho de partículas em escoamento em tempo real.






Figura 8: Representação das frações de mármore.

### Algoritmo de Segmentação


Para o estudo de detecção, todas as frações dos fragmentos de mármore, granito e quartzo foram estudadas separadamente. A técnica da DFT-2D apresentou boa precisão na segmentação, captando tanto a variedade de material quanto a variedade de tamanho. Exemplos de resultados podem ser vistos na Figura 9 e 10.



(A)




(B)




(C)


Figura 9: Detecção de fragmentos dos quatro materiais diferentes. (A) Mármore; (B) Granito; (C) Quartzo.




(A)



(B)




(C)



(D)





(E)

Figura 10: 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.

### Aplicativo de Caracterização de Sólidos

Após a detecção, avaliou-se a capacidade de estimação de tamanho de partículas. Para isso, seria interessante que o sólido estudado fosse detectado individualmente.

Um grupo de fragmentos de quartzo foi analisado em escoamento antes de passar pela etapa de peneiramento. Os fragmentos maiores foram separados em três grupos de formato semelhante, (i) grandes, (ii) médios e (iii) pequenos.

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 de centímetros a partir da referência da largura da calha: 466 pixels equivalem a 12,5cm.

Na Figura 11 foi ilustrado um exemplo de detecção dos fragmentos em que é possível identificar um fragmento de cada subgrupo. A caixa delimitadora ao lado de cada fragmento indica as coordenadas utilizadas para encontrá-los na matriz de características. Em verde, o subgrupo de menor tamanho; em amarelo, tamanho intermediário; e azul, maior tamanho.

Os maiores e menores eixos aparentes de fragmentos em cada subgrupo foram medidos pelo método do paquímetro. A amostragem laboratorial considerou 10 fragmentos em cada grupo. A medida estimada pelo aplicativo foi comparada com a medida experimental e o resultado pode ser visto na Tabela 1.




Figura 11: Imagem de referência para identificação dos sólidos medidos.

Tabela 1. Validação da estimativa de tamanho de fragmento para quartzo. MD = média e DP = desvio padrão.

	Tamanho		Tamanho Real (mm)			
	Estimado (mm)		Maior Eixo		Menor Eixo	
	Maior Eixo	Menor Eixo	MD	DP	MD	DP
<b>P</b>	9,3	3,9	7,3	0,7	5,5	0,9
<b>M</b>	12,5	8,2	11,8	1,3	9,1	1,6
<b>G</b>	19,7	13,6	17,3	2,3	11,0	1,1

Os resultados mostraram que os tamanhos estimados têm valores dentro, ou pelo menos próximos, da faixa delimitada pelos desvios padrão calculados. O resultado foi esperado, levando em consideração os erros associados ao processamento das imagens e de medição. Os erros de processamento podem acrescentar pixels ao reconstruir as bordas da imagem. Os erros de medição dependem da sensibilidade e experiência do operador para detectar, em partículas irregulares, os menores e maiores eixos reais.

Estendendo a caracterização para a análise de cascalho de perfuração de poços de petróleo, verificou-se a capacidade do aplicativo estimar descritores geométricos para o cálculo de propriedades morfológicas. Na Figura 12 foi apresentado um exemplo da aplicação dessa ferramenta onde em (A) tem-se a imagem original, fornecida como entrada aos algoritmos de segmentação e em (B), a imagem binarizada, ponto de partida para o cálculo das estimativas.

Na Figura 12 foram detectados 69 objetos, dentre os quais seis, com a numeração em seu interior, foram selecionados para validação das estimativas.




Figura 12: (A) Imagem fornecida ao aplicativo de caracterização; (B) Imagem segmentada fornecida como resposta.  
Fonte: O autor.

Para melhor visualização dos fragmentos escolhidos, estes foram destacados e mostrados,

em proporção de tamanho, na Figura 13. Os resultados da análise são mostrados nas tabelas e imagens a seguir.



Figura 13: Sólidos selecionados para análise morfológica. Fonte: O autor.

Na Tabela 2 foram listados os descritores área e perímetro e as propriedades arredondamento, circularidade e excentricidade. Na Tabela 3 foi 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 calculou todos os eixos em todas as direções e retorna os valores máximo e mínimo encontrados.

Tabela 2 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
68	78,4	35,8	0,77	0,73	0,67

Tabela 3 Validação do tamanho de partícula.

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

Comparando os resultados obtidos na Tabela 2 com os sólidos destacados na Figura 13, 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.

Como pode ser observado na coluna do erro da Tabela 3, 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 do maior eixo medido depende da capacidade visual do operador. Ainda assim, os resultados podem ser considerados bastante satisfatórios.

As análises geométricas podem ser utilizadas como ferramentas estatísticas para 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.

### Aplicativo de Classificação de Sólidos

Para o estudo da classificação, avaliou-se a capacidade de uma CNN em classificar as amostras em relação à faixa de tamanho obtida com a separação por peneiras laboratoriais. Para essa análise, foram estudados cascalhos de perfuração.

A CNN pré-treinada recebeu como entrada o DS1 e, após o ajuste dos pesos do módulo de aprendizado específico, o modelo apresentou acurácia de 60,25%.

É interessante salientar 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 na forma de Matriz Confusão (Figura 14), onde as amostras preditas corretamente encontram-se na diagonal principal e as predições equivocadas nas outras posições. A variação na intensidade de azul na diagonal indica que, quanto mais escuro, maior o número de amostras preditas corretamente para a classe. A variação da intensidade em laranja representa o oposto, quanto mais escuro, maior o número de amostras preditas incorretamente para a classe.

Os resultados apresentados não foram considerados bons, dessa forma, seguiram-se os estudos com o segundo banco de imagens, DS2.

A escolha de aumentar o tamanho das sub-imagens ocorreu pelo fato de que, nos casos em que há fragmentos muito grandes, não é possível identificar as bordas, o que dificulta a detecção e extração de características pelas

camadas convolucionais. Isso é refletido na etapa de classificação, que conseqüentemente recebe menos atributos, podendo gerar resultados incorretos, classificações equivocadas. De fato, essa mudança aumentou significativamente a performance da CNN, que atingiu 94% de acurácia. Esse resultado pode ser visto na Matriz Confusão da Figura 15.

CLASSE VERDADEIRA	CLASSE PREDITA				
	125	41	55	1	20
11	11	209	12	9	1
50	50	25	164	3	0
30	30	54	3	142	13
73	73	13	11	2	143
	CLASSE PREDITA				
	43,3%	61,1%	66,9%	90,4%	80,8%
	56,7%	38,9%	33,1%	9,6%	19,2%

Figura 14: Matriz Confusão para o banco de imagens DS1.

CLASSE VERDADEIRA	CLASSE PREDITA				
	40	0	0	0	0
0	0	40	0	0	0
3	3	1	36	0	0
0	0	4	0	36	13
4	4	0	0	0	36
	CLASSE PREDITA				
	85,1%	88,9%	100%	100%	100%
	14,9%	11,1%	0%	0%	0%

Figura 15: Matriz Confusão para o banco de imagens DS2.

Os resultados apresentados indicam que a CNN treinada com o DS2 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 do que os demais.

## CONCLUSÃO

A partir dos resultados apresentados, pode-se concluir que os algoritmos, tanto de segmentação quanto de classificação, mostraram grande potencial de adaptabilidade para diversos tipos de rocha e em tamanhos variados.

Os resultados das análises morfológicas sugeriram que as estimativas poderiam se aplicar não somente a materiais diferentes, mas em tamanhos variados, abrindo possibilidade

para criação de outras estimativas funcionais. Ainda há a possibilidade de implementação dos algoritmos para funcionamento em tempo real, com monitoramento automático em processos de sólidos em escoamento, como as peneiras vibratórias para separação de cascalhos do fluido de perfuração nas plataformas de exploração de petróleo e gás. Esta aplicação, que configura a continuidade desse estudo, já vem sendo desenvolvida pelo Grupo de Pesquisa do LEF/UFRRJ.

## AGRADECIMENTOS

Os autores agradecem à Universidade Federal Rural do Rio de Janeiro e ao Laboratório de Escoamento de Fluido Giulio Massarani (LEF/UFRRJ) pela infraestrutura de pesquisa; ao CNPq pelas bolsas de Iniciação Científica; à CAPES/PROEX (EPBQ/UFRRJ) pela bolsa de Doutorado e apoio para participação no evento e ao CENPES/PETROBRAS pelos recursos aportados no Projeto de Pesquisa No. 4600580875.

## REFERÊNCIAS

- BALLARD, D.H.; BROWN, C.M.; Computer Vision.. Englewood Cliffs, New Jersey 07632, Prentice-Hall, Inc ., 1982. ISBN 0-13-165316-4.
- 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.
- ESQUEF, I.A.; ALBUQUERQUE, M.P.; ALBUQUERQUE, M.P.; Processamento Digital de Imagens. Centro Brasileiro de Pesquisas Físicas – CBPF, 2003.
- BARROS, H. C. (2015), Processo de Secagem de *Morinda citrifolia* L. em Secador de Radiação com Lâmpadas Refletoras, Utilizando Planejamento Composto Central Rotacional. PPGEQ/UFPA - Belém - PA, 136p.
- NASCIMENTO, L.D. (2015), Aplicação da Metodologia de Superfície de Resposta Durante a Secagem de Sementes de Painço em Leito de Jorro, *Anais do XXXVII ENEMP 2015 - Congresso Brasileiro de Sistemas Particulados*, p.466-471, São Carlos - SP.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- 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.
- NAJARIAN, K.; SPLINTER, R. *Biomedical Signal and Image Processing*. CRC Press – Taylor & Francis Group. Curso PISB 2017.2, p.92, 2006
- OLIVEIRA FILHO, K. S. Fundamentos de Radiodiagnóstico por imagem. Instituto de Física da UFRGS, 1999.
- ORDOÑEZ, M.F.C. Efeito do empacotamento de partículas nas propriedades mecânicas e tribológicas de misturas de argila-rocha. Dissertação (Mestrado em Ciências e Engenharia de Materiais) – Universidade de Caxias do Sul. Caxias do Sul, p. 136, 2015.
- 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.