

Estratégia de Avaliação da Eficiência do Processo de Peneiramento Utilizando Sensoriamento Remoto

Saulo N. Matos* Thomas V. B. Pinto** Vinicius S. Moreira***
Tiago A. Moraes*,*** Jacó D. Domingues*,** Paulo H. T. F. Alves**
Gustavo Pessin** Thiago A. M. Euzebio**

* Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV), Ouro Preto, MG, Brasil (e-mails: saulo.neves.matos@aluno.itv.org, jaco.domingues@aluno.itv.org).

** Instituto Tecnológico Vale, MG, (e-mails: thomas.pinto@itv.org, paulo.alves@pq.itv.org, gustavo.pessin@itv.org, thiago.euzebio@itv.org)

*** Vale SA, Brasil, (e-mails: vinicius.silva.moreira@vale.com, tiago.moraes@vale.com)

Abstract: In mining, the sieving process is a common method of classification based on particle's sizes. The sieves used in this process classify the material into two fractions: undersize, composed of fine particles; and oversize, composed of coarse particles. In this work, a strategy for evaluating the performance of sieve classification by measuring the degree of fragmentation of the particles of oversize is presented. A two-dimensional LiDAR laser scanner is used to scan the analyzed surface, from which statistical indices are calculated and are used as an input to a Random Forest technique, responsible for classifying the degree of fragmentation of the material. Test results indicate an accuracy around 98 % of the chosen classification models.

Resumo: Na mineração, o processo de peneiramento é um método usual de classificação baseado no tamanho das partículas minerais. As peneiras usadas nesse processo classificam o material em duas frações: *undersize*, composto por partículas finas; e *oversize*, composto por partículas grossas. Neste trabalho é apresentada uma estratégia de avaliação da performance de classificação de peneiras através da medição do grau de fragmentação das partículas do *oversize*. É utilizado um *laser scanner* bidimensional do tipo LiDAR para varredura da superfície analisada, a partir da qual são calculados índices estatísticos que servem de entrada para uma técnica *Random Forest*, responsável por classificar o grau de fragmentação do material. Os resultados de testes indicam uma acurácia em torno de 98% dos modelos de classificação obtidos.

Keywords: LiDAR 2D; Remote Sense; Sieving; Random Forest, Roughness.

Palavras-chaves: LiDAR 2D; Sensoriamento Remoto; Peneiramento; *Random Forest*; Rugosidade.

1. INTRODUÇÃO

A mineração é essencial para a economia global e o desenvolvimento da sociedade e atualmente, o setor vem passando por intensas mudanças para se manter produtivo (Gnoni et al., 2020). Por isso, a indústria busca a implementação de inovações digitais com o uso de dispositivos, métodos e sistemas digitalizados capazes de reduzir custos e melhorar a produtividade e eficiência dos negócios (Barnewold and Lottermoser, 2020). Tem-se como exemplo os sistemas automáticos capazes de mensurar informações do processo para assim melhorar as condições e pontos de operação.

A avaliação da granulometria de partículas é um tema recorrente na busca de melhoria da eficiência de proces-

sos de tratamento de minério. Existem várias técnicas para determinar tamanho e distribuição de partículas. Na indústria mineral são comumente utilizadas técnicas de visão computacional, sobretudo com o uso de câmera e varredura tridimensional a *laser*. Porém, tais técnicas possuem contras, uma vez que a primeira necessita de fontes de iluminação externa e manutenções constantes, devido à insalubridade do ambiente; e a segunda requer um hardware de alto custo.

O presente trabalho tem por objetivo sugerir uma nova estratégia para avaliar o processo de peneiramento, analisando o grau de fragmentação de materiais granulosos oriundos do *oversize*, transportados via correia transportadora, por meio de varredura bidimensional a *laser*.

Oversize é o fluxo materiais grossos que são retidos pela peneira e a análise das partículas de minério presente no *oversize*, por vezes, mostra a presença de partículas finas, que deveriam estar presentes no fluxo de *undersize*, que é a porção de materiais finos que atravessam a peneira. A presença de partículas finas no *oversize* é um indicativo de baixa eficiência de operação da peneira. Essa informação é útil para ajustar parâmetros de operação do peneiramento visando melhorar a eficiência do processo.

Para avaliação do fluxo de *oversize*, utiliza-se a tecnologia LiDAR (*light detection and ranging*) para varredura bidimensional do material, de forma que por meio da análise da rugosidade de sua superfície, é possível avaliar a eficiência de peneiras.

2. REVISÃO BIBLIOGRÁFICA

Nesta Seção é apresentada uma revisão sucinta sobre os trabalhos relacionados ao tema de avaliação de particulados, em que são mostrados trabalhos que medição é feita com o uso de câmera ou LiDAR 3D.

2.1 Uso de câmera para avaliação de partículas

Em Hamzeloo et al. (2014), uma técnica de visão de máquina é apresentada para avaliar tamanho de partículas oriundas do circuito de britagem de um concentrador de cobre. Para avaliar o tamanho das partículas, é realizado o processamento das imagens com o auxílio de uma rede neural artificial, a qual utiliza a técnica Análise do Componente Principal (PCA).

Maerz (1998) usou métodos ópticos de processamento digital de imagens para determinar tamanho e formato de partículas de agregados, a fim de complementar o processo de peneiramento, ou seja, a proposta do trabalho é utilizar métodos ópticos para classificar particulados em cenários que o uso da peneira é inviável ou improdutivo. Para tal, foi utilizado o software WipFrag Granulometry System para se obter o formato e tamanho dos agregados, bem como feito por Núñez et al. (2011).

Trabalhos envolvendo processamento de imagens 2D para análise granulométrica é um tema bastante recorrente como pode-se perceber nos trabalhos propostos por Maerz et al. (2018), Schleifer and Tessier (2018), Salinas et al. (2005), Chang and Chung (2012), Al-Thyabat et al. (2007), Mora and Kwan (2000) e Aldrich et al. (2010).

Existem alternativas comerciais que promovem a análise granulométrica de materiais, como o VisioRock da Metso, o BeltMetrics da Motion Metrics e o 3DPM da MBV System, porém são produtos de alto custo e que utilizam câmera, instrumento o qual pode apresentar desvantagens em ambientes industriais, uma vez que existem limitações relacionadas a poeira e iluminação do local, que podem interferir na medição.

2.2 Uso de LiDAR 3D para avaliação de partículas

Engin and Maerz (2019) utilizaram a tecnologia LiDAR para determinar a distribuição do tamanho de partículas de agregados de construção civil. Com o uso de um *laser scanner* 3D, efetuaram a varredura a *laser* dos materiais

em pilha a fim de se obter uma nuvem de pontos 3D, a qual descreve a superfície dos agregados. Dessa forma, desenvolveram um algoritmo capaz de realizar a análise da nuvem de pontos obtidas pelo instrumento, de maneira a obter o modelo de cada partícula e seu tamanho, levando em consideração sua altura e a proporção da sua área em relação à área total da superfície escaneada.

Utilizando a mesma tecnologia, porém com um algoritmo diferente, Engin et al. (2020) mediram a granulometria de rochas fragmentadas e compararam o resultado do uso do *terrestrial* LiDAR com o obtido utilizando o software WipFrag Granulometry System para o processamento de imagens bidimensionais.

Campbell and Thurley (2017) e Ge et al. (2020), também fizeram o uso do *terrestrial* LiDAR, de forma que utilizaram-no para mensurar o tamanho de fragmentos em uma mina subterrânea. Kaartinen and Tolonen (2008), apresentam a abordagem de determinar o tamanho de partículas de minério, baseada na combinação de uma balança, instalada na correia transportadora, e um *laser scanner* 3D.

O uso de varredura tridimensional a *laser* é comumente abordado em trabalhos acadêmicos, os quais utilizam *lasers scanner* 3D, também conhecidos como *terrestrial* LiDAR. Porém, devido disponibilidade e ao baixo custo, optou-se, neste trabalho, o uso do LiDAR bidimensional, de forma que ao ser instalado acima do mensurando, ele é capaz de efetuar a varredura 2D do material, de modo que são coletados dados para análise da eficiência do peneiramento.

3. MOTIVAÇÃO

Atualmente, não é comum o uso de instrumentos capazes de avaliar a eficiência das peneiras de usinas de beneficiamento de minério. O que é comumente feito é a medição do desempenho das peneiras por meio de uma inspeção visual da granulometria do material. Essa estratégia traz uma variabilidade no desempenho do peneiramento, uma vez que a observação é sensitiva e está atrelada a disponibilidade do operador e ao seu nível de habilidade e acuidade visual.

Adicionalmente, em função do número de peneiras, os operadores não conseguem ficar de forma dedicada em cada peneira e, dessa forma, oportunidades de aumento de taxa em uma dada linha deixam de ser realizadas quando o profissional suporta a verificação de outra peneira. É importante considerar que existem atividades operacionais mais críticas, que podem desviar os profissionais que observam as peneiras.

Um sistema dedicado também reduziria a exposição aos riscos associados à inspeção sensitiva. A eliminação da exposição a situações de eventuais projeções de material da peneira ou eventos similares é mais efetiva que as medidas de mitigação que são empregadas atualmente.

4. PENEIRAMENTO NA INDÚSTRIA DE PROCESSAMENTO MINERAL

O processo de peneiramento é um estágio de classificação largamente utilizado na indústria mineral. Nele são usados

equipamentos mecânicos, peneiras, que classificam o material de entrada com base na granulometria do minério. As peneiras possuem *decks*, telas com aberturas de tamanho pré-definido, que separam o material que as alimenta em dois fluxos, *oversize* e *undersize*. O *oversize* é composto por partículas grossas, maiores do que o tamanho de abertura da *deck*, que ficam retidos na tela são e direcionadas para fora da peneira. O *undersize* é composto por partículas finas que atravessam as aberturas do *deck* e seguem uma direção diferente. Ambos os fluxos produzidos no peneiramento são usualmente transportados por correias transportadoras para os processos subsequentes adequados. Na Figura 1 é mostrada uma peneira vibratória.



Figura 1. Peneira vibratória. Fonte: (Santos et al., 2020)

O processo de peneiramento pode ser realizado “a úmido” ou “a seco”. O peneiramento “a seco” acontece quando o material que alimenta as peneiras apresenta umidade natural; já o peneiramento “a úmido”, ou “via úmida”, ocorre quando o material de alimentação está em forma de polpa ou recebe água adicional por meio de *sprays* convenientemente dispostos sobre os *decks* de peneiramento (Chaves and Peres, 2012).

A eficiência do processo de peneiramento em separar as partículas finas das grossas está sujeito a parâmetros como: Umidade do minério. O material seco contendo partículas com alta umidade superficial, ou seja, entre 5 e 8% de umidade, torna a operação de classificação extremamente difícil, de modo que só poderá ser feita por via úmida. Isso ocorre, pois a água exerce um efeito capilar, aglomerando as partículas em grandes blocos de minério e com isso, as partículas finas são carregadas para o *oversize* junto às partículas grossas (Chaves and Peres, 2012); Taxa de alimentação. Taxas altas de alimentação, além da capacidade de absorção das peneiras, tendem a sobrecarregar as telas com minério, o que causa arraste das partículas finas para o *oversize*.

Além disso, no peneiramento “a seco”, muitas vezes, o peneiramento torna-se uma tarefa complicada dado que, normalmente, é aplicado a formas irregulares de partículas e sem auxílio de injeção de água na tela da peneira, fazendo com que uma partícula com um tamanho próximo ao da abertura nominal da peneira de teste possa passar apenas quando apresentado em uma posição favorável (Wills, 2006).

Segundo De São José et al. (2017), uma forma de avaliar a eficiência é mensurar a relação entre a quantidade de partículas menores que a abertura da tela da peneira que a atravessam e a quantidade de tais partículas existentes

na alimentação. Outra abordagem, seria medir o grau de fragmentação das partículas do *oversize*, ou seja, analisar a presença de materiais finos, menores que a abertura da peneira que foram retidos em sua superfície.

5. METODOLOGIA

Esse trabalho propõe um método para avaliar o grau de fragmentação do minério na correia transportadora oriundo do *oversize* do peneiramento. Para tal, avalie-se a rugosidade da superfície do material, de modo que caso exista uma grande quantidade de particulados finos, significa que o peneiramento está em baixo desempenho, uma vez que uma peneira em condições de funcionamento apropriado, faz com que materiais finos atravessem a peneira e não permaneçam retidos.

Desse modo, utiliza-se a tecnologia LiDAR, com o uso de um *laser scanner* bidimensional para que seja feita a varredura da superfície material não classificado e avaliada sua rugosidade. Para isso, instala-se o dispositivo acima do material alvo, de modo que o feixe de *laser* aponte perpendicularmente para o mensurando. Para garantir melhores resultados na medição, a superfície do alvo deve ser perpendicular ao *scanner* para uma melhor reflexão (Chan, 2010). Portanto, quanto menor o ângulo de incidência, maior a precisão da varredura. Na Figura 2 é mostrada a localização do sistema proposto e a configuração da medição.




Figura 2. Localização do sistema de medição proposto.

Foi montada uma plataforma de teste, onde o *laser scanner* RPLiDAR S1 da marca Slamtec foi fixado a uma altura de meio metro de distância de um recipiente. Três tipos de agregados foram considerados para haver uma variação granulométrica: areia (fino), pó de brita (intermediário) e brita (grosso). Na Figura 3 é mostrada a fixação do *laser scanner* e o recipiente abastecido de areia.

O *Robot Operating System* (ROS) foi usado para aquisição e manipulação dos dados oriundos do *laser scanner*. O ROS é um *software* que contém uma série de bibliotecas e ferramentas para construção de aplicações em robótica. Foi usado o pacote disponibilizado pela Slamtec para ser usado como *driver* do dispositivo, de modo que é feita a leitura dos dados do sensor, os quais são convertidos em mensagem do tipo “*LaserScan*”. Em outras palavras, é criado um nó, ou seja, um executável do ROS, para inicializar o sensor e adquirir seus dados. A frequência de publicação das mensagens em um tópico, termo usado no ROS para a estrutura que contém mensagens do tipo ROS, foi de 10 Hz.



Figura 3. Plataforma de testes usada no experimento.

Para manipular os dados do *laser scanner*, foi criado outro nó, este para subscrever as mensagens do tópico supracitado. Por meio dos dados obtidos da mensagem “*LaserScan*” coletou-se as informações de *range*, que é um vetor que contém as medidas de distâncias entre o sensor e o mensurando e o ângulo de incremento entre cada medição. Os dados apresentam-se em coordenadas polares (r, θ) , em que r representa o *range*, θ o ângulo de incremento entre cada medição. Eles foram convertidos para coordenadas cartesianas (x, y) , em que se obteve a altura entre o sensor e o alvo y e delimitar a faixa do ângulo de abertura para limitar a varredura apenas a largura do recipiente x .

Feita a configuração do *laser scanner* para o teste, foram criados três cenários diferentes para cada material, inicialmente com o material não compactado, compactado e muito compactado, conforme é mostrado na Figura 4.

6. RESULTADOS

Foram feitas as varreduras dos materiais a partir das quais foram calculados índices estatísticos SII (Sum of Absolute Input Increments), variância e mediana do vetor das variações de altura medido pelo *laser scanner* para que seja possível avaliar a rugosidade da superfície dos materiais durante o procedimento. Com o intuito de analisar cada índice calculado, foram feitas as distribuições normais de cada índice para cada material e cenário diferente, assim como pode ser observado na Figura 5.

Para o pré-processamento dos dados foi usado um filtro média móvel para atenuação de ruídos, de modo que os dados tratados foram usados para criar um *dataset* de entrada de uma técnica de *machine learning* chamada *Random Forest*. Essa técnica trata-se de um conjunto de árvores de decisão, em que cada uma é gerada usando um subconjunto aleatório de dados de um *dataset*. Ela é muito utilizada para problemas que englobam classificação e regressão. Para sua criação foi utilizado o *software* Weka, que é uma coleção de algoritmos de aprendizado de máquina para resolver problemas de uma grande quantidade de dados. Os parâmetros de entrada foram os índices SII, mediana e variância e o *label*, o grau de fragmentação, classificado como grosso, intermediário e fino. Foram testados dois modelos de *Random Forest*, um utilizando 25 árvores e outro com 50. O diagrama de fluxo é mostrado na Figura 6.



(a) Areia não compactada, compactada e muito compactada.




(b) Pó de brita não compactado, compactado e muito compactado.




(c) Brita não compactada, compactada e muito compactada.


Figura 4. Diferentes cenários usados no teste.



(a) Distribuição normal dos índices mediana, variância e SII para materiais não compactados, em que a curva em azul representa areia, laranja pó de brita e preto brita.



(b) Distribuição normal dos índices mediana, variância e SII para materiais compactados, em que a curva em azul representa areia, laranja pó de brita e preto brita.



(c) Distribuição normal dos índices mediana, variância e SII para materiais muito compactados, em que a curva em azul representa areia, laranja pó de brita e preto brita.

Figura 5. Distribuições normal obtidas nas varreduras.




Figura 6. Diagrama de fluxo da *Random Forest*.

O algoritmo proposto, utilizando *Random Forest* com 25 e 50 árvores, foi treinado 30 vezes alterando-se sua semente aleatória (*seed*). A aleatoriedade é usada para definir dentro do *dataset* quais dados serão usados para formar as árvores de decisão. Dessa forma, evita-se um *overfitting* da técnica, ou seja, uma técnica bem treinada apenas para aquele *dataset* utilizado. Foram analisados os erros RMSE de cada modelo e posteriormente calculadas a média e desvio padrão para cada configuração da *Random Forest*. Para a *Random Forest* de 25 árvores foi obtida uma média de erro RMSE igual a $0,1085$ e desvio padrão igual a $2,4656e - 04$. Já para a *Random Forest* de 50 árvores a média do erro foi igual a $0,1069$, enquanto o desvio padrão foi de $2,1413e - 04$.

Por meio dos dados de média e desvio padrão, obtidos para cada modelo, foi possível plotar o gráfico *boxplot*, mostrado na Figura 7 e comprovar a normalidade da distribuição, usando o teste de Shapiro-Wilk. Foi comprovada a normalidade de ambos os modelos, uma vez que pelo teste de Shapiro-Wilk, para uma distribuição ser considerado normal, *p-value* deve ser superior a $0,05$. A RF25 obteve *p-value* igual a $0,69$ e a RF50, *p-value* igual a $0,09$. Nas Figuras 8 e 9 são mostradas as distribuições de cada modelo.




Figura 7. *Boxplot* da RF com 25 e 50 árvores.

Matriz de confusão é um meio de avaliar o desempenho da técnica *Random Forest*. Os valores da diagonal dessa matriz representam as classes corretamente classificadas. A Tabela 1 mostra a matriz de confusão de cada modelo




Figura 8. Distribuição normal RF25.




Figura 9. Distribuição normal RF50.

treinado. A acurácia de cada modelo é calculada dividindo o total de classes corretamente classificadas pelo total de instâncias. A RF25 obteve taxa de acerto igual a $97,81\%$, enquanto RF50 $97,89\%$. Utilizando-se 50 árvores, foi observado maior acurácia e menor média de erro. Além disso, por meio do *Welch Two Sample t-test*, foi obtido *p-value* inferior a $0,05$ mostrando que existe uma diferença significativa em relação aos dois modelos.

Tabela 1. Matrizes de confusão para os modelos propostos.

Fino	Grosso	Intermediário
18142	0	566
0	17172	2
621	1	17962

(a) Matriz de confusão para *Random Forest* com 25 árvores.

Fino	Grosso	Intermediário
18182	0	526
0	17172	2
615	1	17968

(b) Matriz de confusão para *Random Forest* com 50 árvores.

Pela taxa de acerto apresentada, obteve-se uma solução instrumentada competente para classificação de grau de fragmentação de forma útil a ser utilizada para retroali-

mentação em estratégias de controle de regulação de alimentação na peneira para obtenção da operação de forma a evitar finos no *oversize*.

7. CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentada uma nova estratégia para avaliar o processo de peneiramento, que por meio de um *laser scanner* bidimensional, a superfície do minério oriundo do *oversize* é escaneada, com o intuito de detectar a presença de finos. Foi feito um experimento, em que três agregados de construção civil de diferentes granulometrias e em diferentes graus de compactação foram escaneados, de forma que foram calculados índices estatísticos, os quais tiveram o comportamento analisado, percebendo-se a influência da rugosidade da superfície do material nos índices calculados. Estes, foram usados como parâmetros de entrada para uma *Random Forest*, a qual foi responsável por classificar o grau de fragmentação do material, de maneira que foi obtida uma taxa de acerto em torno de 98%, provando-se um funcionamento adequado para classificação de particulados e um bom indicio para uma aplicação do sistema em um ambiente industrial. Para trabalhos futuros, sugere-se o teste de outras abordagens de classificação e a aplicação do método em uma correia transportadora industrial, bem como integrá-lo ao sistema de automação da usina.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), números 402759/2018-4 e 444425/2018-7; da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); do Instituto Tecnológico Vale (ITV); da Universidade Federal de Ouro Preto (UFOP) e da Vale S.A.

REFERÊNCIAS

- Al-Thyabat, S., Miles, N., and Koh, T. (2007). Estimation of the size distribution of particles moving on a conveyor belt. *Minerals Engineering*, 20(1), 72–83.
- Aldrich, C., Jemwa, G., Van Dyk, J., Keyser, M., and Van Heerden, J. (2010). Online analysis of coal on a conveyor belt by use of machine vision and kernel methods. *International Journal of Coal Preparation and Utilization*, 30(6), 331–348.
- Barnewold, L. and Lottermoser, B.G. (2020). Identification of digital technologies and digitalisation trends in the mining industry. *International Journal of Mining Science and Technology*, 30(6), 747–757.
- Campbell, A. and Thurley, M. (2017). Application of laser scanning to measure fragmentation in underground mines. *Mining Technology*, 126(4), 240–247.
- Chan, A. (2010). *Using 3D terrestrial laser scanning technique to determine volume changes of a cobble beach*. Master's thesis, Delft University and Technologies.
- Chang, F.J. and Chung, C.H. (2012). Estimation of riverbed grain-size distribution using image-processing techniques. *Journal of Hydrology*, 440, 102–112.
- Chaves, A.P. and Peres, A.E.C. (2012). *Britagem, Peneiramento e Moagem*, volume 3. Oficina de Textos, 5 edition.
- De São José, F., Junior, M.L.T., and Pereira, C.A. (2017). Análise de rota de peneiramento de minério de ferro no itm da namisa sa—um estudo de caso. *HOLOS*, 4, 299–307.
- Engin, I.C., Maerz, N.H., Boyko, K.J., and Reals, R. (2020). Practical measurement of size distribution of blasted rocks using lidar scan data. *Rock Mechanics and Rock Engineering*, 53. doi:https://doi.org/10.1007/s00603-020-02181-5.
- Engin, I.C. and Maerz, N.H. (2019). Size distribution analysis of aggregates using lidar scan data and an alternate algorithm. *Measurement*, 143, 136–143.
- Ge, Y., Lin, Z., Tang, H., Zhong, P., and Cao, B. (2020). Measurement of particle size of loose accumulation based on alpha shapes (as) and hill climbing-region growing (hc-rg) algorithms. *Sensors*, 20(3), 883.
- Gnoni, M.G., Bragatto, P.A., Milazzo, M.F., and Setola, R. (2020). Integrating iot technologies for an “intelligent” safety management in the process industry. *Procedia manufacturing*, 42, 511–515.
- Hamzeloo, E., Massinaei, M., and Mehrshad, N. (2014). Estimation of particle size distribution on an industrial conveyor belt using image analysis and neural networks. *Powder Technology*, 261, 185–190.
- Kaartinen, J. and Tolonen, A. (2008). Utilizing 3d height measurement in particle size analysis. *IFAC Proceedings Volumes*, 41(2), 3292–3297.
- Maerz, N.H. (1998). Aggregate sizing and shape determination using digital image processing. In *Center For Aggregates Research (ICAR) Sixth Annual Symposium Proceedings*, 195–203.
- Maerz, N.H., Palangio, T.C., and Franklin, J.A. (2018). Wipfrag image based granulometry system. In *Measurement of Blast Fragmentation*, 91–99. Routledge.
- Mora, C. and Kwan, A. (2000). Sphericity, shape factor, and convexity measurement of coarse aggregate for concrete using digital image processing. *Cement and concrete research*, 30(3), 351–358.
- Núñez, F., Silva, D., and Cipriano, A. (2011). Characterization and modeling of semi-autogenous mill performance under ore size distribution disturbances. *IFAC Proceedings Volumes*, 44(1), 9941–9946.
- Salinas, R., Raff, U., and Farfan, C. (2005). Automated estimation of rock fragment distributions using computer vision and its application in mining. *IEEE Proceedings-Vision, Image and Signal Processing*, 152(1), 1–8.
- Santos, M.S., Pinto, T.V., Júnior, Ê.L., Cota, L.P., Souza, M.J., and Euzébio, T.A. (2020). Simheuristic-based decision support system for efficiency improvement of an iron ore crusher circuit. *Engineering Applications of Artificial Intelligence*, 94, 103789.
- Schleifer, J. and Tessier, B. (2018). Fragscan: A tool to measure fragmentation of blasted rock. In *Measurement of blast fragmentation*, 73–78. Routledge.
- Wills, B.A. (2006). *Mineral Processing Technology: An introduction to the practical aspects of ore treatment and mineral recovery*. Elsevier Science and Technology Books.