

-XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

DESENVOLVIMENTO E AVALIAÇÃO PRELIMINARES DE ALGORITMO AUTOMÁTICO PARA ESTIMATIVA DE GRANULOMETRIA EM LEITOS FLUVIAIS A PARTIR DE IMAGENS DIGITAIS

Gabriel Sulzbach Pereira¹ ; Daniel Gustavo Allasia Piccilli¹ ; Vanessa Sari¹; Yamila Soledad Chicherit¹ Rodrigo Girardon Della Pace¹; Gustavo Schefelbanis Araujo¹ e Eliane Fischborn¹

Abstract: Grain-size characterization of riverbeds is essential for understanding hydro-sedimentological processes and guiding environmental management. However, this is a time-consuming and costly process, which limits its application to a few locations. This study presents the development and preliminary evaluation of an automatic model to estimate the grain size of riverbed gravels from digital images. The experiment was conducted in the Rancho do Amaral stream basin, located in the state of Rio Grande do Sul, Brazil. Channel bed images containing a visible scale were processed using computer vision techniques implemented in Python, including bilateral filtering, CLAHE, edge detection, morphological closing, watershed segmentation, and ellipse fitting. The equivalent diameter of particles was automatically extracted and compared with two traditional methods: manual pebble count and visual analysis using ImageJ. The evaluation considered the D10, D30, D50, D70, and D90 percentiles, based on mean absolute error (MAE) and mean absolute percentage error (MAPE). Preliminary results indicated good agreement in the central percentiles (D50 and D70), with greater discrepancies at the distribution extremes. The model showed promising performance, offering a faster and more accessible alternative compared to traditional methods, and can support sediment monitoring and regional water resource management.

Resumo: A caracterização granulométrica de leitos fluviais é essencial para compreender processos hidrossedimentológicos e orientação da gestão ambiental. No entanto, trata-se de um processo demorado e oneroso, o que limita sua aplicação a poucos locais. Este estudo apresenta o desenvolvimento e avaliação preliminar de um modelo automático para estimar a granulometria de pedregulhos a partir de imagens digitais. O experimento foi realizado na bacia do arroio Rancho do Amaral, no estado do Rio Grande do Sul. As imagens do leito, contendo régua de escala, foram processadas com técnicas de visão computacional em Python, incluindo filtragem bilateral, CLAHE, detecção de bordas, fechamento morfológico, segmentação por watershed e ajuste de elipses. O diâmetro equivalente das partículas foi extraído automaticamente e comparado a dois métodos tradicionais: contagem manual de seixos (Pebble Count) e análise visual com ImageJ. A avaliação considerou os percentis D10, D30, D50, D70 e D90, com base em erro absoluto médio (MAE) e erro percentual absoluto médio (MAPE). Os resultados preliminares indicaram boa concordância nos percentis centrais (D50 e D70), com discrepâncias nas extremidades da distribuição. Conclui-se que o modelo apresenta desempenho promissor, oferecendo uma alternativa

1) Programa de Pós-Graduação em Engenharia Civil e Ambiental, (UFSM), gabrielpereirars@gmail.com; dallasia@gmail.com; vanessa.sari@ufsm.br; yamichicherit@hotmail.com; gustavo.esa@hotmail.com; rodrigodellapace02@gmail.com; elianefischborn17@gmail.com.

mais rápida e acessível em comparação aos métodos tradicionais, e pode apoiar o monitoramento sedimentar e a gestão hídrica da região.

Palavras-Chave – Granulometria, Processamento de Imagens, Leito Fluvial.

1 INTRODUÇÃO

A caracterização granulométrica de leitos fluviais é essencial para a compreensão dos processos hidrossedimentológicos e para a orientação da gestão ambiental. A análise do tamanho de grãos de cascalho em córregos é fundamental nos cálculos de transporte de sedimentos, na mitigação de eventos extremos de inundação, na preservação da biodiversidade nos habitats aquáticos (Zimmermann *et al.*, 2008; Cislighi *et al.*, 2016), bem como na engenharia de restauração e estabilidade de rios e no monitoramento ambiental (Bunte e Abt, 2001; Sulaiman *et al.*, 2014). No entanto, trata-se de um processo demorado e oneroso, o que limita sua aplicação a poucos locais.

Tradicionalmente, as distribuições de tamanho de grão ou granulometria foram coletadas por meio de medição física de clastos e contagem ao longo do leito do rio (*Pebble Count*), por diferentes metodologias (Bunte e Abt, 2001; Church e Zimmermann, 2007; Bevenger e King, 1995). Essas técnicas não são apenas demoradas, propensas ao viés do operador e perturbadoras para o meio ambiente, mas também exigem tamanhos de amostra grandes (centenas de seixos) para estimar com precisão a natureza característica dos grãos em cada local (Purinton e Bookhagen, 2019; Sulaiman *et al.*, 2014). Assim, é necessário desenvolver metodologias que agilizem esse processo, reduzindo custos sem comprometer a precisão.

Diante disso, a medição a partir de fotografias é uma boa opção para aumentar o tamanho da amostra e diminuir o trabalho de campo, ao mesmo tempo em que cobre áreas maiores. As abordagens fotográficas, que comumente contam com a identificação manual para reduzir o tempo de campo, ainda exigem muito tempo para extrair as informações necessárias em laboratório (Miazza *et al.*, 2024). Cislighi, Chiaradia e Bischetti (2016), por exemplo, compararam a estimativa do diâmetro do grão por meio de métodos fotográficos e contagem manual de pedras, tanto em condições controladas de laboratório quanto em ambientes de campo. Apesar de bons resultados, as divergências entre os métodos visuais e a contagem de campo variaram de 8% a 72% para cada porcentagem de diâmetro característico avaliada.

Um método alternativo desenvolvido nas últimas décadas é a aplicação de algoritmos e redes neurais para extrair automaticamente o tamanho de grãos em imagens digitais de leitos fluviais, o que tem se mostrado viável para medir granulometria e sedimentos fluviais de tamanhos maiores: Purinton e Bookhagen (2019) aplicaram o algoritmo *PebbleCountsAuto* em rios de montanha nos Andes do noroeste da Argentina, com bons resultados nos percentis médios e potencial para uso em larga escala. Sulaiman *et al.* (2014) utilizaram segmentação automatizada para analisar amostras pequenas de carga de fundo no rio Rasil, na Malásia, obtendo boas estimativas mesmo com massas reduzidas. Miazza *et al.* (2024) testaram os métodos *BASEGRAIN*, *PebbleCountsAuto* e *GALET* sobre ortoimagens obtidas por VANT em um rio de leito cascalhoso nos Alpes suíços, com resultados coerentes em relação às medições manuais, apesar de variações nos percentis. Chen *et al.* (2022) desenvolveram o modelo *GrainID*, baseado em redes neurais convolucionais, treinado com dados de campo e laboratório na China e no Canadá, que apresentou alta acurácia e superou os métodos tradicionais em diferentes cenários.

Diante desse contexto, este estudo teve como objetivo desenvolver um algoritmo automático para estimar a granulometria de pedregulhos em leitos fluviais, aplicado à bacia do Rancho do Amaral, no estado do Rio Grande do Sul. A proposta metodológica incluiu a comparação entre o

desempenho do modelo automatizado e técnicas tradicionais de análise, como a contagem de seixos (*Pebble Count*) e a interpretação manual de imagens digitais. No intuito de oferecer uma alternativa eficaz para a caracterização de sedimentos, pela distribuição granulométrica, de forma mais ágil, acessível e menos onerosa que os métodos convencionais, este trabalho busca contribuir para o avanço de ferramentas aplicadas ao monitoramento ambiental e à gestão de recursos hídricos da região.

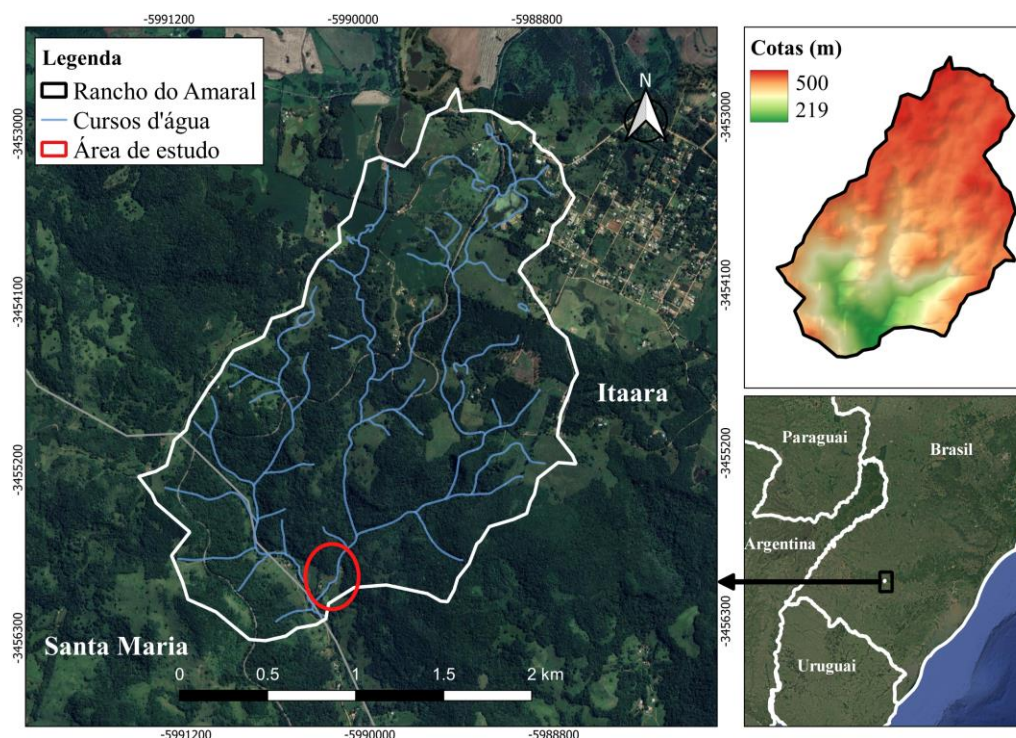
2 METODOLOGIA

Com o objetivo de desenvolver um algoritmo para estimativa automática da granulometria de pedregulhos em leitos fluviais por meio de imagens digitais, a metodologia adotada foi estruturada em quatro etapas: (I) caracterização da área de estudo e aquisição das imagens; (II) processamento digital automatizado para extração dos diâmetros; (III) comparação com métodos tradicionais (ImageJ (Rasband, 2008) e *Pebble Count*); e (IV) avaliação estatística da acurácia. Cada etapa é detalhada nas subseções a seguir.

2.1 Área de estudo e obtenção de imagens

A área de estudo situa-se na bacia do arroio Rancho do Amaral, afluente do rio Vacacaí-Mirim, localizado entre os municípios de Santa Maria e Itaara, no estado do Rio Grande do Sul (Figura 1). Localizada no rebordo do Planalto Meridional, essa bacia possui relevo abrupto, com cotas variando entre 200 e 500 metros, e área de drenagem aproximada de 4,45 km². A cobertura do solo é composta predominantemente por vegetação nativa (47,4%) e áreas com uso agropecuário (35,4%) (MapBiomas, 2024). O clima da região é classificado como subtropical úmido (Cfa), segundo a classificação de Köppen-Geiger (Peel et al., 2007), com precipitação média anual entre 1900 e 2100 mm, distribuída uniformemente ao longo do ano (INMET, 2024). A geologia local é caracterizada por litologias basálticas, areníticas e colúviais (CPRM, 2006; Maciel Filho, 1990). Os solos predominantes na bacia são o Argissolo Vermelho-Amarelo (54%) e o Neossolo Regolítico (46%) (EMBRAPA, 2006).

Figura 1 – Localização e Cotas da bacia do Rancho do Amaral.



A bacia hidrográfica foi escolhida por apresentar canais com morfologia em degraus e piscinas (*step-pool*), típicos de ambientes com elevada declividade. Essas feições estão associadas a processos de instabilidade, como erosão e movimentos de massa (Zimmermann et al., 2008; Grant et al., 1990). Sua estabilidade depende das dimensões dos blocos que compõem os degraus, responsáveis por dissipar a energia do fluxo (Church e Zimmermann, 2007), o que evidencia a importância do conhecimento da granulometria local. As imagens do leito utilizadas neste estudo foram obtidas por Pereira (2024) e incluem dez registros dos pedregulhos no leito com régua posicionada sobre o canal, conforme mostra a Figura 2.

Figura 2 – Conjunto de imagens do leito do canal da bacia do Rancho do Amaral, organizadas conforme sua aplicação nas etapas de calibração e validação do algoritmo. Fonte: Pereira, (2024).



2.2 Processamento digital automatizado para extração dos diâmetros das partículas

Para estimar automaticamente os diâmetros esféricos equivalentes de pedregulhos em leitos fluviais a partir de imagens do leito do rio com régua visível, foi desenvolvido um algoritmo de processamento digital implementado em *Python*, utilizando bibliotecas de visão computacional como o OpenCV. O fluxo completo do processamento está representado na Figura 3.

Com base em abordagens adotadas em estudos prévios, como Miazza et al. (2024) e Purinton e Bookhagen (2019), o processo inicia-se pelo pré-processamento da imagem, convertendo-a para tons de cinza e aplicando um filtro bilateral, que preserva as bordas enquanto suaviza ruídos, a fim de facilitar a identificação de pedras. Em seguida, utiliza-se o detector de bordas de *Canny*, seguido por uma operação morfológica de fechamento, com o objetivo de unir contornos descontínuos. A segmentação é realizada por meio da extração dos contornos externos, mantendo-se apenas aqueles cuja área supera o limiar mínimo de 2000 pixels, a fim de eliminar partículas irrelevantes ou ruídos. Para cada contorno identificado, ajusta-se uma elipse, a partir da qual os eixos principais (A e B) são extraídos automaticamente. A escala da imagem (em metros por pixel) é definida com base na distância real conhecida da régua visível, previamente anotada a partir da posição dos pixels. O

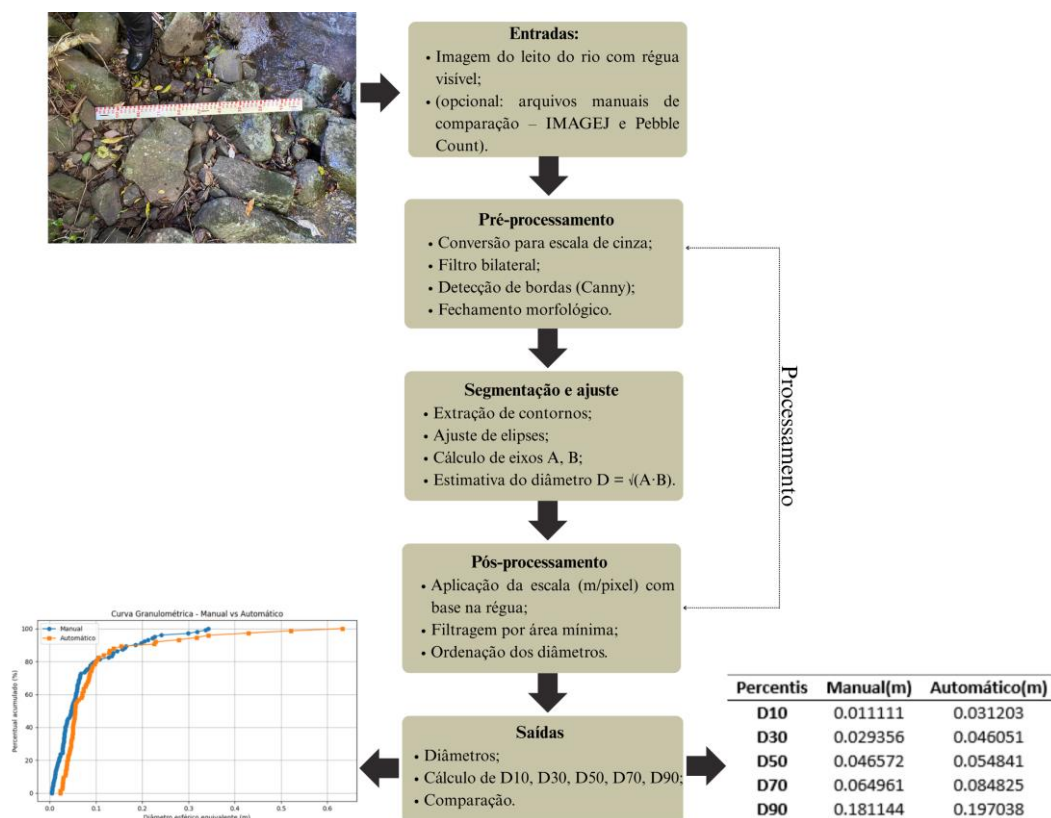
diâmetro equivalente (D) é então estimado pela raiz quadrada do produto entre os eixos principais (Equação 1):

$$D = \sqrt[2]{A * B} \quad (1)$$

Sendo D o diâmetro equivalente, A o eixo mais longo e B o eixo intermediário.

Foram utilizadas sete imagens para a calibração interativa e manual dos parâmetros do algoritmo (como área mínima, bordas e elipse), e três imagens adicionais foram reservadas para a etapa de validação dos resultados. Na etapa final, os diâmetros detectados são ordenados para cálculo dos percentis granulométricos (D_{10} , D_{30} , D_{50} , D_{70} e D_{90}), e os resultados foram exportados para posterior comparação com métodos tradicionais (análise manual de imagem e *Pebble Count*).

Figura 3 – Fluxo completo do processamento do algoritmo de detecção de diâmetros



2.3 Comparação com métodos tradicionais

Com o objetivo de avaliar o desempenho do algoritmo de reconhecimento automático, os resultados obtidos pelo algoritmo automático foram comparados com dois métodos tradicionalmente utilizados na caracterização granulométrica: a análise manual de imagens digitais e a medição em campo por contagem de seixos (*Pebble Count*).

A análise manual foi realizada a partir das mesmas imagens utilizadas pelo algoritmo, processadas no *software* ImageJ (Rasband, 2008). Em cada imagem, procedeu-se à identificação visual e à medição dos eixos principais de cada partícula, com posterior cálculo do diâmetro nominal (Equação 1). Os diâmetros obtidos foram utilizados para gerar a curva granulométrica acumulada e

os percentis D10, D30, D50, D70 e D90, possibilitando a comparação direta com os resultados do modelo automatizado.

Já o método de contagem de seixos (*Pebble Count*) foi aplicado em campo, no mesmo local onde as imagens foram registradas. A coleta dos dados seguiu o procedimento em zigue-zague proposto por Bevenger e King (1995), conforme descrito por Bunte e Abt (2001), utilizando régua e trena para medir os eixos A e B de cada partícula. O diâmetro nominal foi estimado igualmente pela Equação 1. Os dados de campo foram, então, comparados com o somatório obtidos pelo algoritmo automático e pelo método manual, permitindo a avaliação estatística da acurácia de cada abordagem.

2.4 Avaliação estatística da acurácia dos resultados

A avaliação da acurácia do algoritmo proposto foi conduzida por meio da comparação dos resultados obtidos com base em métricas estatísticas entre os percentis totais (soma de todos os diâmetros obtidos nas três imagens utilizadas na validação) gerados pelo método automático, em relação aos diâmetros totais obtidos pela análise manual de imagem (ImageJ (Rasband, 2008)). O método de referência utilizado foi o de amostragem direta em campo (*Pebble Count*). Para essa comparação, foram considerados os percentis D10, D30, D50, D70 e D90, extraídos a partir das distribuições granulométricas obtidas por cada abordagem.

As métricas estatísticas utilizadas foram o Erro Absoluto Médio (MAE) e o Erro Percentual Absoluto Médio (MAPE). O MAE (Equação 2) representa a média das diferenças absolutas entre os percentis estimados e os valores de referência obtidos em campo, sendo sensível à magnitude dos erros, independentemente da direção. Já o MAPE (Equação 3) expressa esses desvios de forma relativa em termos percentuais. Em ambos os casos, valores mais próximos de zero indicam melhor desempenho do modelo, ou seja, maior proximidade entre os percentis gerados automaticamente e aqueles medidos pelo método de referência.

$$MAE = \frac{1}{n} \sum_{i=1}^n |D_i - D_r| \quad (2)$$

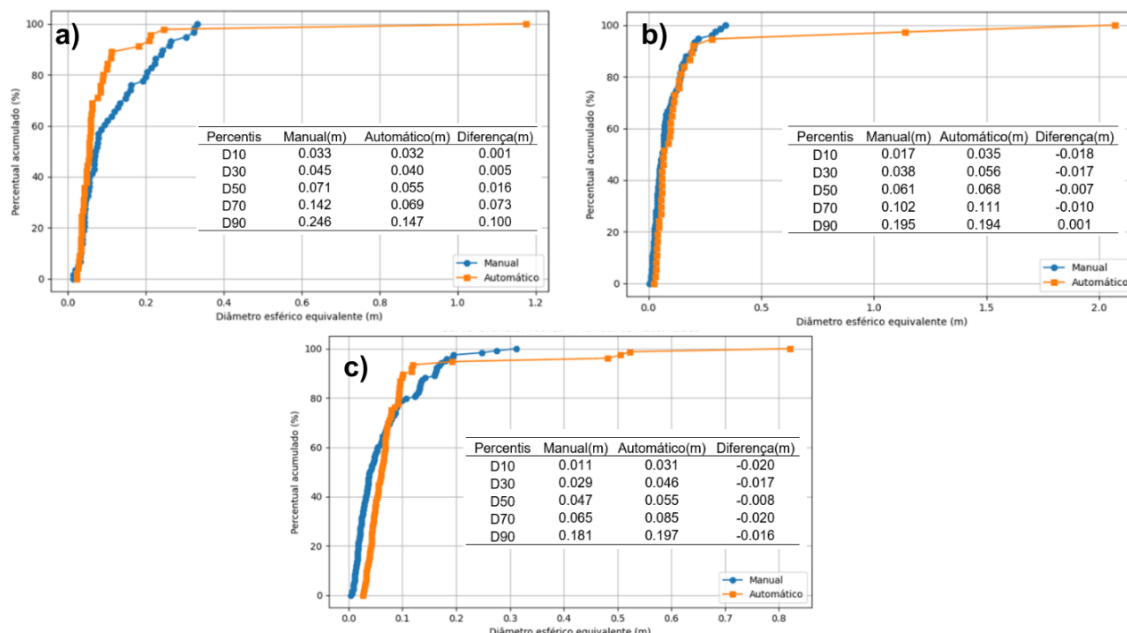
$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|D_i - D_r|}{D_r} \quad (3)$$

Sendo D_i o valor estimado do diâmetro representativo do percentil avaliado e D_r o diâmetro correspondente obtido pelo método de referência.

3 RESULTADOS E DISCUSSÃO

A Figura 4 apresenta os resultados preliminares da comparação visual e os percentis da segmentação realizada pelo algoritmo automático em relação às partículas identificadas manualmente com o *software* ImageJ (Rasband, 2008). Na primeira imagem de validação (a), o modelo automático reconheceu 46 partículas, enquanto a análise manual contabilizou 59. Observa-se pequena diferença nos percentis inferiores a D50 (até 0,016 m), enquanto nos percentis superiores foram registradas diferenças maiores (0,07 m e 0,10 m). Na segunda imagem de validação (b), o algoritmo detectou 38 partículas, frente a 76 identificadas manualmente. Os percentis obtidos mostraram boa aproximação com os valores manuais, com diferenças máximas de até 0,01 m. Já na terceira imagem (c), o número de partículas reconhecidas automaticamente foi de 75, comparado a 103 na análise manual, também apresentando baixas diferenças entre os percentis, com valores absolutos inferiores a 0,02 m.

Figura 4 – Comparação entre as curvas granulométricas e percentis obtidos pelo algoritmo automático e pela análise manual considerando as imagens de validação: (a) primeira imagem, (b) segunda imagem e (c) terceira imagem.




É possível observar que o modelo apresenta boa proximidade de alguns percentis com os dados analisados manualmente, mostrando quantidades similares em certos percentis, provavelmente devido à facilidade de identificação das partículas de determinados tamanhos. Esse comportamento também foi identificado por Chen et al. (2022), que apontam que partículas bem definidas e as condições de imagem são favoráveis, os métodos automáticos tendem a gerar resultados próximos aos métodos tradicionais, como a análise manual. Apesar disso, o número de pedregulhos encontrados de forma automática foi consideravelmente menor que o encontrado no método manual. Esse fato pode ser explicado por limitações do algoritmo, como observado por Purinton et al. (2019), que destacam que métodos automáticos, particularmente os baseados em visão computacional, podem falhar na identificação de partículas menores ou com contornos menos definidos. De acordo com Miazza et al. (2024), esse fenômeno pode ser atribuído à dificuldade de segmentação de partículas pequenas, que muitas vezes não são bem delineadas no processamento de imagem.

Outro fator observável é que o modelo automático superestimou os valores maiores que D90, provavelmente devido ao reconhecimento de pedregulhos maiores nas imagens. Esse fenômeno pode ser explicado pela quantidade limitada de amostras utilizadas na calibração. Assim como apontado por Sulaiman et al. (2014), a quantidade de amostras é um fator crítico no treinamento de modelos de visão computacional, e modelos com um número reduzido de imagens podem não capturar toda a variabilidade dos sedimentos, resultando em discrepâncias nas extremidades da distribuição granulométrica. A subestimação de partículas menores e a superestimação de partículas maiores, foi observada também por Purinton et al. (2019), que indicam que a segmentação automática de partículas grandes ou pequenas pode ser propensa a erros, principalmente quando o modelo não tem uma grande diversidade de dados de treinamento.

A Figura 5 apresenta a comparação das curvas granulométricas acumuladas obtidas pelo somatório das três imagens utilizadas na etapa de validação, considerando os métodos automático, totalizando 159 partículas, o método manual (ImageJ), com 238 partículas, e o *Pebble Count*, com 100 partículas.

Figura 5 – Curva granulométrica acumulada (Automático x Manual x *Pebble Count*)



A Tabela 1 permite ampliar a análise comparativa entre os percentis obtidos pelos métodos manual e automático em relação ao *Pebble Count*. No percentil D10, ambos os métodos apresentaram os maiores desvios relativos, com valores de MAPE superiores a 140% no manual e 280% no automático, o que indica baixa acurácia na identificação de partículas menores. No D30, os dois métodos apresentaram desempenho semelhante, com leve vantagem para o manual em termos de MAE. O percentil D50 destacou-se como o de melhor desempenho do método automático, com o menor erro absoluto (0,003 m) e MAPE inferior a 6%, evidenciando boa aderência à curva de referência. No D70, embora ambos os métodos apresentem desvios, o algoritmo automático manteve melhor aproximação à curva acumulada, com menor MAE e MAPE. Por fim, no D90, o método manual apresentou desempenho ligeiramente superior, com erro absoluto menor, o que sugere que a análise manual pode ser mais eficiente na detecção de blocos maiores.

Tabela 1 – Comparação dos percentis granulométricos entre os métodos manual, automático e *Pebble Count*, com respectivos erros MAE e MAPE

Percentil	Manual Total (m)	<i>Pebble Count</i> (m)	MAE Manual	MAPE Manual
D10	0.018	0.007	0.011	145.592
D30	0.036	0.024	0.012	49.337
D50	0.047	0.052	0.005	9.521
D70	0.069	0.115	0.046	39.809
D90	0.215	0.264	0.049	18.520
Percentil	Automático Total (m)	<i>Pebble Count</i> (m)	MAE Auto	MAPE Auto
D10	0.028	0.007	0.021	287.879
D30	0.037	0.024	0.013	52.239
D50	0.055	0.052	0.003	5.728
D70	0.084	0.115	0.032	27.438
D90	0.181	0.264	0.082	31.184

Os resultados indicam um bom desempenho na estimativa dos diâmetros das partículas em campo. No entanto, tanto os modelos baseados em análise de imagem, manual e automático, apresentaram dificuldades consideráveis em identificar partículas pequenas quando comparados aos

dados de campo, especialmente nos percentis D10. Essa discrepância pode ser atribuída à dificuldade de identificação de sedimentos menores nas fotografias, devido à presença de vegetação e sujeira no leito. Conforme mencionado por Cislighi, Chiaradia e Bischetti (2016), a vegetação no leito, seja viva ou morta, aliada a partículas mais finas e sujeira, pode dificultar a identificação das bordas dos grãos.

Embora os resultados preliminares mostrem que o modelo automático teve bom desempenho nos percentis intermediários, com capacidade de fornecer resultados consistentes e em tempo mais rápido, ele ainda apresenta limitações nas extremidades da distribuição granulométrica. Para aprimorar sua precisão em partículas muito pequenas ou grandes, uma possível melhoria seria a implementação de técnicas de segmentação avançada e filtros adaptativos, como sugerido por Purinton et al. (2019). O aumento do número de imagens usadas no treinamento e calibração do modelo também é essencial para melhorar a generalização, especialmente para partículas de tamanhos extremos. Com esses ajustes, o modelo pode gerar resultados ainda mais confiáveis, adequados para aplicações práticas na gestão de recursos hídricos, como estimativas de estabilidade e modelagem de processo.

4 CONCLUSÃO

Os resultados preliminares obtidos demonstram que o modelo automático proposto apresenta um bom desempenho na estimativa dos diâmetros das partículas em leitos fluviais, como os encontrados na bacia do Rancho do Amaral, especialmente nos percentis intermediários (D50, D70). Quando comparado ao método manual, o algoritmo automático mostrou-se capaz de fornecer resultados consistentes, com boa aderência aos valores de referência, principalmente para partículas de tamanho médio. Embora tenha apresentado boas estimativas nos percentis centrais, o modelo ainda apresentou limitações nas extremidades da distribuição (D10 e D90), onde a identificação de partículas menores e maiores foi menos precisa. Para melhorar ainda mais a precisão do modelo, especialmente na detecção de partículas pequenas e grandes, é necessário aprimorar a calibração do modelo e aumentar o número de amostras para treinamento. Apesar dessas limitações, o modelo demonstrou ser uma ferramenta promissora para aplicações em estudos hidrossedimentológicos, oferecendo uma alternativa mais rápida e acessível em relação aos métodos tradicionais, contribuindo para o avanço de soluções automatizadas no monitoramento ambiental e na gestão de recursos hídricos da região.

AGRADECIMENTOS

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, do Programa de Pós-Graduação em Engenharia Civil e Ambiental (PPGECAM), a Universidade Federal de Santa Maria (UFSM) e o grupo de pesquisa ECOTECNOLOGIAS.

REFERENCIAS

BEVENDER, G. S.; KING, R. M. (1995). "*A pebble count procedure for assessing watershed cumulative effects.*" USDA Forest Service, Rocky Mountain Forest and Range Experiment Station, Research Paper RM-RP-319, Fort Collins, Colorado, 17 p.

BUNTE, K.; ABT, S. R. (2001). "*Pebble count protocol for the American Rivers Organization: a field guide for the standardization of sediment sampling.*" River Research and Applications, 20(3), pp. 451-463.

- CPRM. (2006). Geologia do Brasil. Serviço Geológico do Brasil, 2ª edição.
- CHURCH, M.; ZIMMERMANN, A. (2007). “*Sediment transport and channel morphodynamics in step-pool streams.*” *Geophysical Research Letters*, 34(6), L06401.
- CHEN, H.; ZHAO, Y.; WANG, L.; LIU, Q.; XU, X. (2022). “*Automatic estimation of sediment size distribution using image processing techniques.*” *Journal of Hydrology*, 101(5), pp. 120-130.
- CISLAGHI, A.; CHIARADIA, P.; BISCETTI, M. (2016). “*Effect of vegetation on sediment transport in step-pool channels.*” *Geomorphology*, 268, pp. 144-158.
- EMBRAPA. (2006). “*Sistema Brasileiro de Classificação de Solos*”. 2ª edição, EMBRAPA, Brasília.
- GRANT, G.E.; MONTGOMERY, D.R.; KOSKI, R.A. (1990). “*Distribution of bedrock and sediment in the Oregon Coast Range, USA.*” *Geological Society of America Bulletin*, 102(10), pp. 1449-1463.
- INMET. (2024). *Instituto Nacional de Meteorologia*. Dados climáticos históricos, disponível em: www.inmet.gov.br.
- MIAZZA, J. A.; CARVALHO, F.; ALMEIDA, S. (2024). “*Segmentation of riverbed gravel using computer vision.*” *Journal of Hydraulic Engineering*, 135(4), pp. 482-494.
- MAPBIOMAS. (2024). *Projeto MapBiomass: Coleção 7. MapBiomass*, disponível em: www.mapbiomas.org.
- MACIEL FILHO, C. (1990). “*Geologia e geomorfologia da região Sul do Brasil.*” *Revista Brasileira de Geociências*, 20(4), pp. 135-147.
- PEEL, M.C.; FINLAYSON, B.L.; MCMAHON, T.A. (2007). “*Updated world map of the Köppen-Geiger climate classification.*” *Hydrology and Earth System Sciences*, 11(5), pp. 1633-1644.
- PEREIRA, G. S. (2024). “*Caracterização dos processos hidromorfológicos em uma região de variação abrupta de relevo.*” Dissertação (Mestrado) – Universidade Federal de Santa Maria, Programa de Pós-Graduação em Engenharia Civil, Santa Maria, RS,
- PURINTON, M.L.; BOOKHAGEN, B. (2019). “*Evaluating automated image segmentation for gravel bed river analysis.*” *Water Resources Research*, 55(8), pp. 1040-1051.
- RASBAND, W.S. (2008). *ImageJ: Image Processing and Analysis Software*. National Institutes of Health, USA, disponível em: <https://imagej.nih.gov/ij/>.
- SULAIMAN, M.; MUSTAFA, Z.; RAZAK, A. A. (2014). “*Challenges in automated sediment analysis in fluvial environments.*” In: *Proceedings of the International Conference on Environmental Modeling*, Kuala Lumpur, Nov. 2014, pp. 350-360.
- ZIMMERMANN, A.; WASSER, E.; SCHUMACHER, H. (2008). “*Morphodynamics and sediment transport in step-pool channels.*” *River Research and Applications*, 24(3), pp. 385-399.