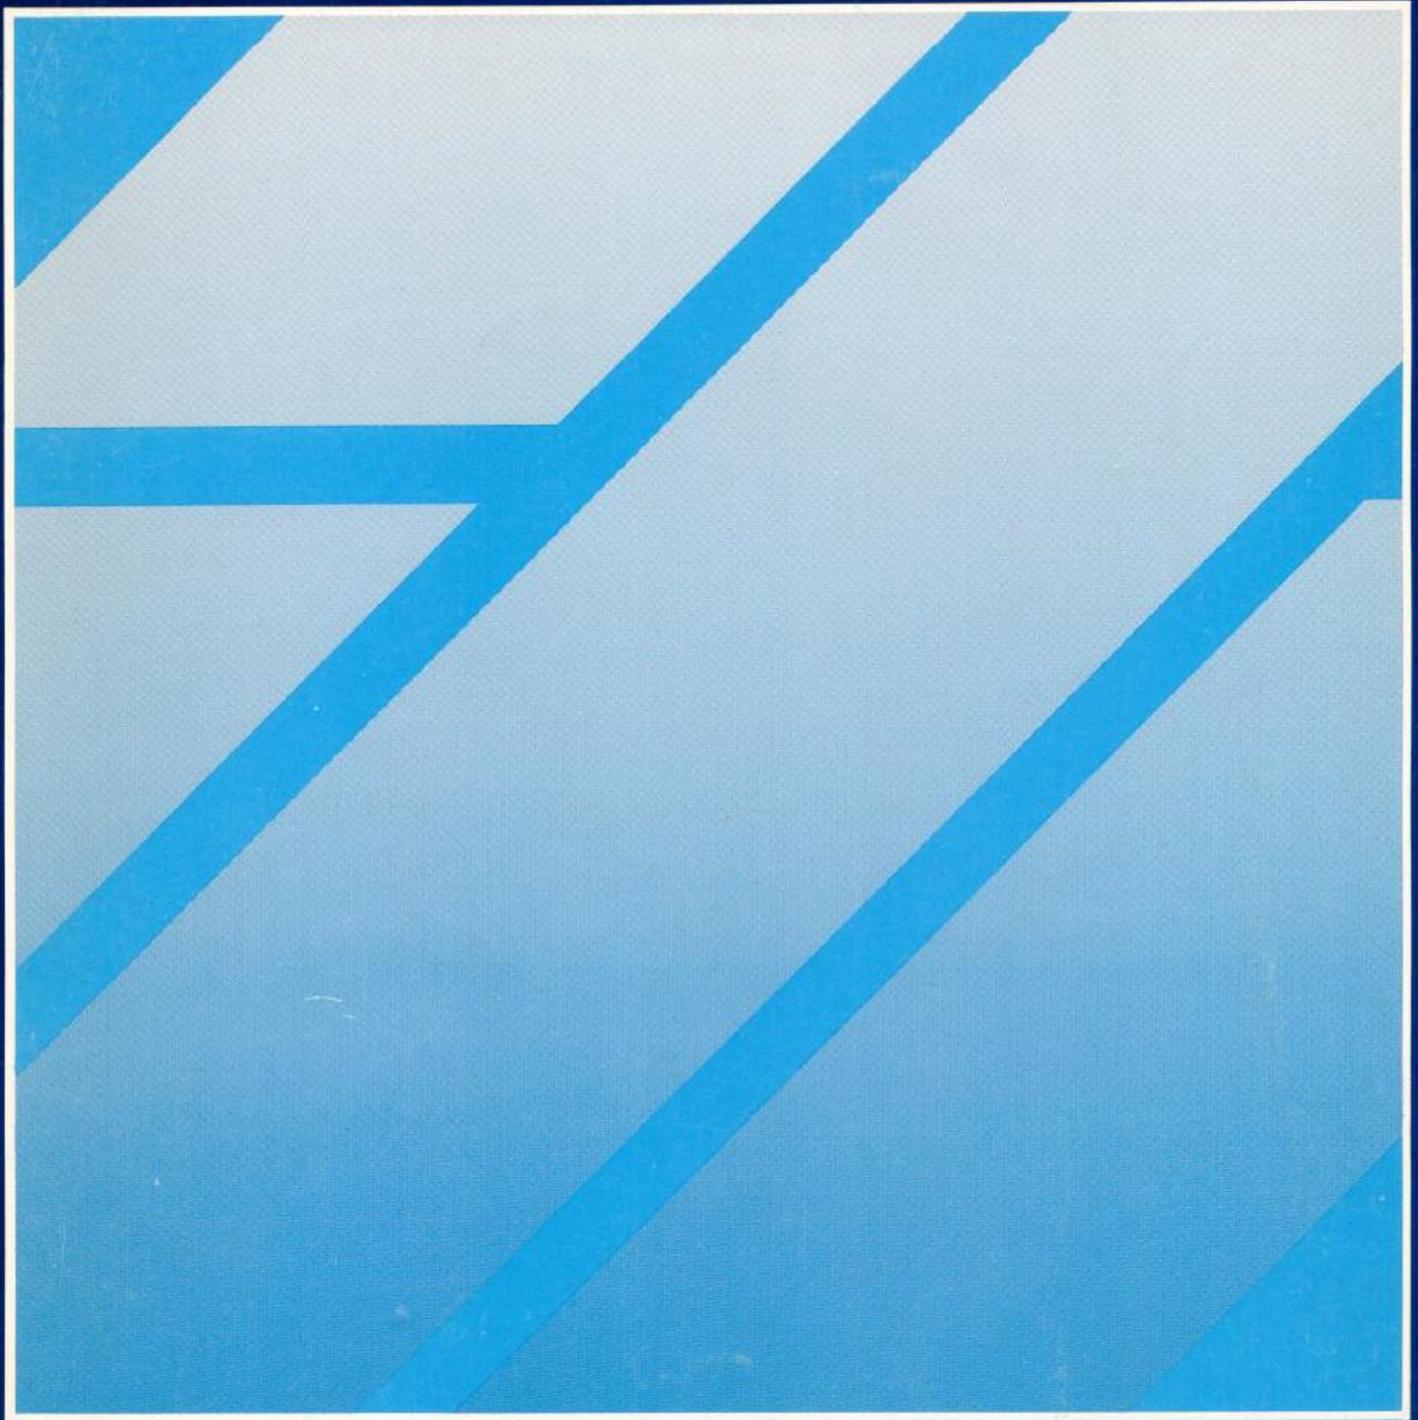




**Revista de la Sociedad Chilena
de Ingeniería Hidráulica**



ISSN 0716-3746 Volumen 39, Número 1, 2024

REVISTA DE LA
SOCIEDAD CHILENA DE
INGENIERÍA HIDRÁULICA

SOCHID

Sede Instituto de Ingenieros de Chile – San Martín 352 – Fono 2 2698 4028 – Santiago CHILE

DIRECTORIO SOCHID

Presidente: Hernán Alcayaga S.
Vicepresidenta: Pamela Muñoz
Tesorero: Damaris Orphanópoulos S.
Directores: Jorge Gironás L.
Cristián Núñez R.
Aldo Tamburrino T.
Secretario General: Francisco Romero B.

DIRECTORES HONORARIOS

Francisco J. Domínguez S. (Q.E.P.D.)
Horacio Mery M.
Eduardo Varas C.
Sergio Radrigán V.
Humberto Peña T.
Ernesto Brown F. (Q.E.P.D.)
Bonifacio Fernández L.
Jorge Bravo S
Luis Ayala R.
Ludwig Stowhas B.
Ricardo González V.
José Vargas B.
Luis Estellé A.
Raúl Demangel C.

EDITOR DE LA REVISTA

Aldo Tamburrino Tavantzis
[*atamburr@ing.uchile.cl*](mailto:atamburr@ing.uchile.cl)
San Martín 352, Santiago
Fono 2 2698 4028
[*www.sochid.cl*](http://www.sochid.cl)

REVISTA DE LA SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA

ÍNDICE

Editorial	1
Detección de velocidad de objetos mediante un sensor RGB-D y aplicación a un frente aluvional Jaime Cotroneo	3
Estimación de la distribución granulométrica superficial utilizando fotogrametría y <i>machine learning</i> Gerardo Zegers, Alex Garcés y Masaki Hayashi	15
Hidro-Grafía Aldo Tamburrino Tavantzis	33

EDITORIAL

En este primer número de la Revista de 2024 se presentan dos artículos, ambos relacionados con técnicas de medición que utilizan análisis de imágenes. En el primero se describe el equipamiento y metodología para detectar alturas de escurrimiento y velocidad de frentes de flujo a escala de laboratorio. El segundo artículo se refiere a la determinación de la granulometría superficial de grandes extensiones de terreno (hectáreas) mediante imágenes adquiridas por un dron y procesadas con metodología de *machine learning*. Para quienes terminamos nuestros estudios de ingeniería hace algunas décadas, especialmente aquellos que hicimos memorias de título experimentales y debimos trabajar en terreno, no pasaba de ser una ficción tener registros continuos espacio-temporales de la deformación del lecho o de la superficie libre, o determinar la granulometría superficial de extensas áreas en un día de trabajo. El rápido avance de la tecnología digital y los relativamente bajos costos de los equipos hace que los sueños o ficciones de antes ahora sean realidad.

Este año tendremos dos importantes actividades presenciales: el décimo Seminario Internacional de Ingeniería y Operación Portuaria (X SIOP) y la XVII Jornada de Hidráulica Francisco Javier Domínguez. Esperamos una alta convocatoria con una gran cantidad de participantes en ambas reuniones.

Como es habitual, la Revista concluye con la tradicional Hidro-Grafía e invitando a colaborar con artículos y opiniones a todos quienes están interesados en las distintas áreas de la ingeniería hidráulica.

Agradecemos la libre difusión de la Revista, cuyos números anteriores pueden descargarse del sitio web de la SOCHID, www.sochid.cl/publicaciones-sochid/revista-sochid/

Aldo Tamburrino Tavantzis
Editor

DETECCIÓN DE VELOCIDAD DE OBJETOS MEDIANTE UN SENSOR RGB-D Y APLICACIÓN A UN FRENTE ALUVIONAL

JAIME COTRONEO^{1,2}

¹Instituto Nacional de Hidráulica, Ministerio de Obras Públicas, Chile

²Estudiante Programa Doctorado Ingeniería Civil, Universidad de Chile, Chile

jaimecotroneo@inh.cl

RESUMEN

Este artículo presenta un estudio sobre el uso de la cámara Intel RealSense D455, basada en tecnología RGB-D, para la detección y seguimiento de objetos en movimiento, y la medición de su velocidad en experimentos hidráulicos. Se evaluó su desempeño realizando ensayos con diferentes objetos geométricos (cubo, pirámide y dodecaedro) desplazándose a distintas velocidades sobre un riel con servomotor. Los resultados mostraron que la cámara D455 es capaz de realizar un seguimiento preciso y determinar la velocidad con buena precisión para los casos del cubo y el dodecaedro, con diferencias porcentuales inferiores al 1,6% respecto a las velocidades reales. Sin embargo, en el caso de la pirámide, se observaron mayores discrepancias (hasta 9,3%), atribuidas a las características geométricas y los reflejos especulares que afectaron la estimación de profundidad. Posteriormente, se aplicó la misma técnica para detectar y medir la velocidad del frente de un pulso aluvional en una instalación experimental. Los datos de altura obtenidos permitieron identificar el avance del frente y calcular su velocidad media mediante un ajuste lineal, demostrando el potencial de esta tecnología para el monitoreo de fenómenos hidráulicos dinámicos. A pesar de las limitaciones puntuales, los resultados generales demostraron el gran potencial de la tecnología RGB-D para el seguimiento de objetos y la medición de velocidades en experimentos hidráulicos, combinando una alta resolución temporal y espacial sobre un área amplia.

Palabras claves: Sensor RGB-D, velocimetría superficial, medición de altura

1. INTRODUCCIÓN Y OBJETIVOS

La experimentación física juega un papel crucial en el avance de la hidráulica contemporánea, ya que muchos aspectos de la dinámica de los flujos aún deben ser clarificados o documentados mediante investigación o aplicaciones prácticas. A lo largo de la historia, las técnicas de instrumentación y medición han sido indispensables para cuantificar los complejos fenómenos hidráulicos, desempeñando un papel crucial en la investigación y en la aplicación en problemas de ingeniería (Ettema et al., 2000; Novak et al., 2010; Frostick et al., 2011, 2017; Sukhodolov, 2015). La instrumentación para la experimentación hidráulica proporciona los medios para observar, apreciar y controlar los procesos de flujo en el laboratorio y en el campo.

Desde los primeros experimentos de Henri de Pitot y Daniel Bernoulli en el siglo XVIII, hasta el arribo de la era moderna, la instrumentación hidráulica ha evolucionado considerablemente para satisfacer las cambiantes demandas de la ciencia fundamental y las aplicaciones prácticas. Tradicionalmente, los experimentos hidráulicos han planteado desafíos significativos en términos de capacidad de instrumentación para medir flujos no uniformes, no estacionarios y turbulentos (Rouse e Ince, 1957). A lo largo de los años, los avances en la sofisticación de la instrumentación y las técnicas de medición han permitido medir más propiedades del flujo y del medio ambiente con una resolución espacial y temporal notablemente alta (Sukhodolov, 2015; Venditti et al., 2016; Williams et al., 2015).

La instrumentación típica utilizada en experimentos hidráulicos incluye mediciones de altura del flujo (limnómetros, sensores ultrasónicos, sensores laser, etc.), de velocidad (veletas, tubos de Pitot, flujómetros de hélice, ADV, PIV, etc.), sensores de presión, instrumentos de medición de caudal, sistemas de adquisición de datos y cámaras de video de alta velocidad, entre otros. Sin embargo, existe una necesidad continua de combinar los avances en instrumentación y métodos con orientación práctica sobre cómo llevar a cabo experimentos hidráulicos de manera efectiva (Novak y Cabelka, 1981).

Recientemente, las nuevas tendencias en instrumentación hidráulica se han enfocado en el desarrollo de técnicas ópticas, acústicas y de procesamiento de imágenes avanzadas (Carfagni et al., 2019). En particular, la tecnología de cámaras tridimensionales (3D) o de profundidad, como las cámaras Intel RealSense series D400, surge como una alternativa potencial para el estudio de flujos superficiales libres inestables y turbulentos, permitiendo simultáneamente una alta resolución temporal y espacial sobre dominios espaciales relativamente grandes.

La cámara Intel RealSense series D400 utiliza estereoscopía activa para estimar la distancia desde la cámara hasta la superficie de un objeto, combinando una cámara digital RGB, dos cámaras infrarrojas (IR) y un láser IR (Carfagni et al., 2019; Giancola et al., 2018). Esta tecnología ha sido implementada previamente en diversos estudios enfocados en topografía, flujos granulares transitorios y flujos aireados como los resaltos hidráulicos (Butkiewicz, 2014; Caviedes-Voullième et al., 2014; Bung et al., 2020).

La precisión y versatilidad de esta tecnología, nos lleva a explorar diferentes campos de investigación en el área hidráulica, como lo es por ejemplo la detección y seguimiento de frentes aluvionales a escala de laboratorio y con ello poder obtener la altura y velocidad de este. Por lo tanto, en este estudio, se investiga la idoneidad del módulo de cámara Intel RealSense y sus sensores de altura (láser) para capturar la superficie del flujo. Se analiza la sensibilidad del instrumento experimentalmente, con el seguimiento elementos de diferentes geometrías y a diferentes velocidades controladas externamente. Además, los datos adquiridos por la cámara se comparan con datos de un frente aluvional obtenidos utilizando otras técnicas, resaltando las ventajas y limitaciones de esta nueva tecnología en el contexto de la experimentación física hidráulica.

2. METODOLOGIA EXPERIMENTAL

2.1 Instalación Experimental

Con el propósito de validar el funcionamiento del equipo para capturar la velocidad, se construye un riel con servomotor de velocidad contralada para movilizar diferentes elementos, como se muestra en la Figura 1. El riel mide 1.5 metros y los rangos de velocidad que alcanza el servomotor son de 0,074 – 0,29 m/s. los elementos que se ocuparon para el seguimiento son un cubo de 5 cm de lado, una pirámide con aristas de 5 cm y un dodecaedro con aristas de 2 cm, como se aprecian en la Figura 2a, Figura 2b y 2c, respectivamente. Las tres piezas fueron impresas mediante una impresora 3D con un error de 0.2 mm. La cámara Intel® RealSense™ D455 fue montada sobre un trípode a 1 metro aproximadamente de altura sobre el riel, de forma perpendicular a este. En la Figura 1a se observa la salida RGB y en la Figura 1b la salida del mapa de altura de la cámara Intel® RealSense™ D455.

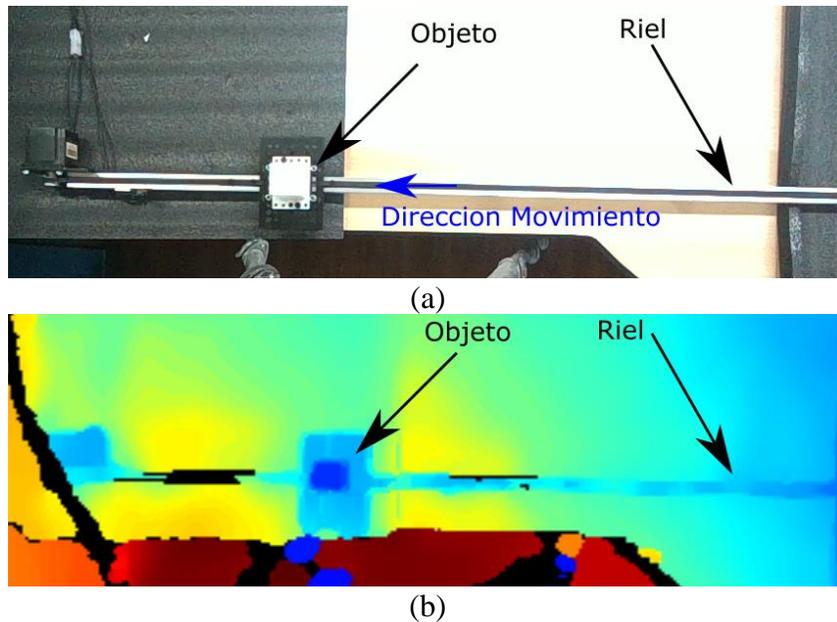


Figura 1. Imágenes obtenidas de la cámara D455. (a) Fotografía de la instalación experimental. (b) Mapa de profundidad obtenida de la misma fotografía mostrada en (a).

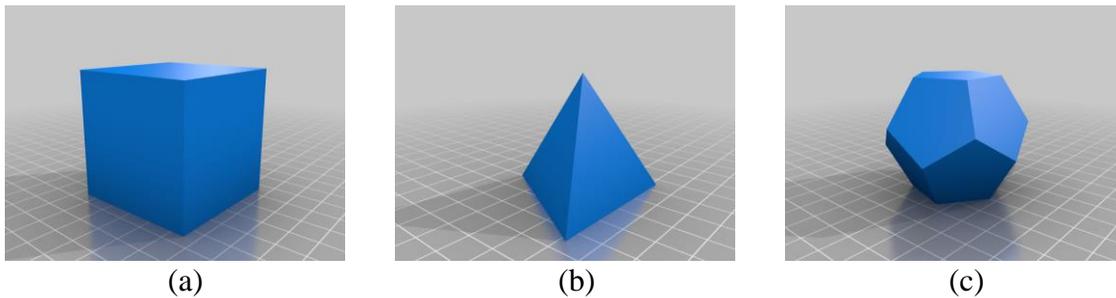


Figura 2. Croquis de los objetos usados. (a) Cubo con lados de 5 cm. (b) Pirámide con aristas de 5 cm. (c) Dodecaedro formado por 12 pentágonos de aristas de 2 cm.

2.2 RGB-D cámara

La cámara seleccionada para este estudio es la Intel® RealSense™ D455. Esta cámara utiliza una tecnología de cámara estéreo activa para generar mapas de profundidad. Cuenta con dos cámaras infrarrojas (IR) y un proyector láser IR que emite un patrón de puntos aleatorios en la escena. Las dos cámaras IR captan este patrón de puntos desde ángulos ligeramente diferentes, lo que permite calcular la profundidad mediante triangulación estéreo. Además de las cámaras de profundidad, la D455 también incluye una cámara RGB para capturar imágenes a color. Esto permite combinar los datos de color con los datos de profundidad, brindando una representación 3D a todo color de la escena. Más detalle se puede ver en la Tabla 1

Tabla 1. Principales características de la cámara Intel RealSense D455

Resolución de profundidad (max)	1280 × 720 px
Resolución RGB (max)	1280 × 1080 px
Frame rate (max)	90 fps
Baseline	95mm
FOV (H × V) at 16:9 in HD	87.0° × 58.0° (±3°)
FOV (H × V) at 8:5	75° × 62° (±3°)
Rango ideal (z axis)	0.6 a 6 m
Tecnología de Profundidad	Active IR stereo
	OmniVision Technologies
Sensor imagen	OV9782

La cámara Intel RealSense D455 es compatible con varias bibliotecas y SDK, como Intel RealSense SDK, OpenCV, ROS (Robot Operating System), y la librería en Python pyrealsense2, entre otras. Esto permite a los desarrolladores integrar fácilmente las capacidades de visión artificial y percepción 3D en sus aplicaciones. En este estudio en particular se usará para la grabación de los videos el software Intel RealSense SDK y para obtener los datos la librería en Python pyrealsense2.

La D455 es capaz de detectar sutiles variaciones de textura en entornos bien iluminados, incluyendo aplicaciones al aire libre. Aunque el sistema fue desarrollado específicamente para aplicaciones con una gran variedad de condiciones de iluminación, se proporcionan orientaciones para superposiciones del proyector óptico para condiciones de poca iluminación o escenas sin textura (Brung et al, 2020). Por otra parte, la cámara no tiene dificultad para determinar profundidades a través de materiales transparentes como acrílico y agua clara, a menos que la sustancia sea altamente reflectante o cree distorsión óptica por refracción.


Se realizaron 12 ensayos diferenciados en 4 velocidades y 3 elementos geométricos, los que se detallan en la Tabla 2.

Tabla 2. Ensayos realizados

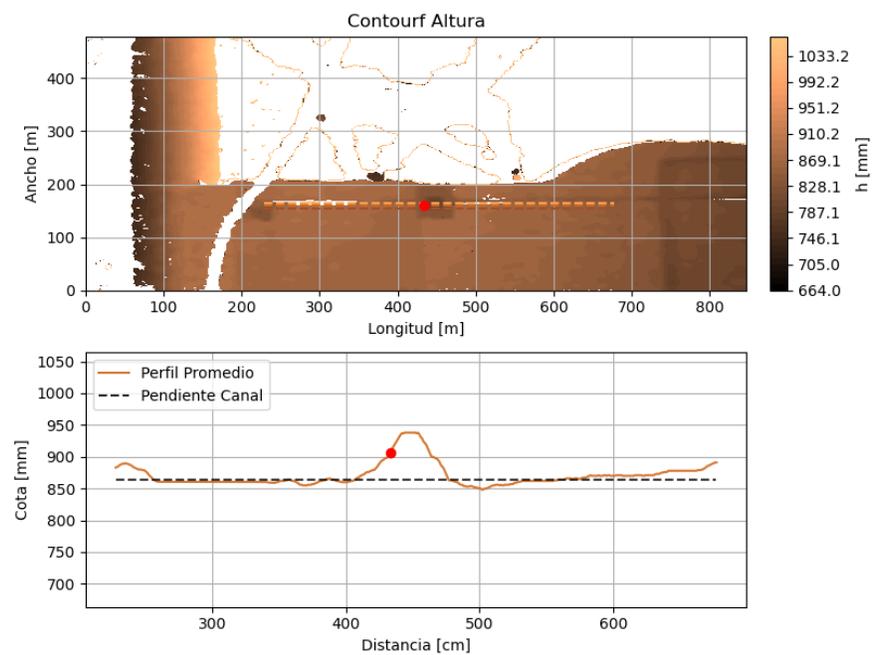
Exp N°	Elemento	Velocidad riel [m/s]
C1	Cubo	0,2904
C2	Cubo	0,1469
C3	Cubo	0,0981
C4	Cubo	0,0737
P1	Pirámide	0,2904
P2	Pirámide	0,1469
P3	Pirámide	0,0981
P4	Pirámide	0,0737
D1	Dodecaedro	0,2904
D2	Dodecaedro	0,1469
D3	Dodecaedro	0,0981
D4	Dodecaedro	0,0737

2.3 Post-procesos

Para poder identificar la velocidad de los elementos en el riel, primero se debe detectar la posición del objeto en el tiempo. Para ello se usan los datos de profundidad de la cámara D455. Se extraen 3 perfiles longitudinales al riel, uno en el centro de este y los otros dos desplazados 2 cm por arriba y abajo del perfil central para después promediar estos 3 perfiles e identificar el primer punto de este perfil promediado que supere un umbral sobre los 5 cm del riel. En las imágenes superiores de las Figura 3a y Figura 3b se observa la vista en planta del mapa de profundidad a diferentes tiempos para el caso del cubo con los 3 ejes longitudinales al riel, donde en color rojo se identifica el vértice con el cual se obtiene el gráfico posición v/s tiempo. En el gráfico inferior de la Figura 3a y 3b se muestra el perfil promedio de los 3 perfiles, identificando el vértice o punto más prominente de cada objeto, registrando su posición en cada fotograma. Las coordenadas de posición obtenidas se graficaron en función del tiempo, generando curvas que reflejaban el desplazamiento de los objetos a lo largo del riel. Para cada curva, se realizó un ajuste lineal mediante mínimos cuadrados, obteniendo la ecuación de una recta cuya pendiente representaba la velocidad del objeto en ese ensayo (Figura 4).



(a)




(b)


Figura 3. La imagen superior corresponde al mapa de profundidad para el ensayo C3 obtenido mediante la cámara D455 y el gráfico inferior al perfil longitudinal promedio. (a) Experimento C3 en $t=1,06$ segundos. (b) Experimento C3 en $t=3,435$ segundos.

3. RESULTADOS


Las Figura 4a, Figura 4b y Figura 4c presentan las curvas de posición en función del tiempo obtenidas a partir de los tres perfiles para los ensayos realizados con el cubo, la pirámide y el dodecaedro a diferentes velocidades del riel (0,2904, 0,1469, 0,0981 y 0,0737 m/s) respectivamente. Para obtener las curvas de posición en función del tiempo, se analizaron los datos de profundidad capturados por la cámara D455 en la zona donde se desplazaban los objetos. Para cada una de estas curvas se les realizó un ajuste lineal mediante mínimos cuadrados obteniendo la velocidad promedio mostrada en la Tabla 3.



(a)



(b)



(c)

Figura 4. Curva de la posición del elemento en función del tiempo. (a) Cubo. (b) Pirámide. (c) Dodecaedro.

En la Tabla 3 se resumen las velocidades obtenidas a partir del análisis de los datos de la cámara D455 para los ensayos con el cubo, pirámide y dodecaedro contrastándolas con las velocidades reales impuestas por el riel. El error se asoció a la diferencia relativa porcentual de velocidades y se calculó mediante la siguiente fórmula:

$$Diferencia [\%] = \frac{V_{intel} - V_{real}}{V_{real}} \times 100 \quad (1)$$

Donde la V_{intel} es el valor obtenido a partir de la pendiente de la curva de posición v/s tiempo de los datos de la cámara D455, y la V_{real} es el valor de velocidad configurado en el servomotor del riel.

Tabla 3. Resultados de las velocidades medias obtenidas mediante ajuste lineal a las curvas de la Figura 4.

Ensayo	Velocidad [m/s]		
	Intel	Real	Diferencia [%]
C1	0,286	0,290	1,5%
C2	0,145	0,147	1,6%
C3	0,098	0,098	0,5%
C4	0,073	0,074	0,9%
P1	0,266	0,290	8,4%
P2	0,135	0,147	8,1%
P3	0,092	0,098	6,0%
P4	0,067	0,074	9,3%
D1	0,288	0,290	0,8%
D2	0,145	0,147	0,9%
D3	0,097	0,098	1,2%
D4	0,073	0,074	1,1%

4. ANALISIS DE RESULTADOS

A partir de los resultados resumidos en la Tabla 3, se observa que la cámara Intel RealSense D455 es capaz de realizar un seguimiento preciso de los objetos en movimiento y determinar su velocidad con buena precisión para los casos del cubo (ensayos C) y el dodecaedro (ensayos D). En estos ensayos, las diferencias porcentuales entre las velocidades medidas por la cámara y las velocidades reales impuestas por el riel son inferiores al 1,6% para todas las velocidades evaluadas.

Sin embargo, en el caso de la pirámide (ensayos P) se aprecia una mayor discrepancia, con diferencias de hasta un 9,3% respecto al valor real. Esta mayor desviación se atribuye principalmente a las características geométricas de la pirámide, que dificultan la correcta detección del vértice utilizado para el seguimiento. A medida que la pirámide se desplaza,

las caras laterales inclinadas pueden generar reflejos o sombras que afectan la definición del vértice en el mapa de profundidad, introduciendo errores en la estimación de la posición.

Otro factor que podría incidir en la menor precisión para el caso de la pirámide es la pendiente de sus caras laterales. Cuando la pirámide se encuentra en ciertas orientaciones, las caras pueden generar reflexiones especulares del patrón de puntos infrarrojo proyectado por la cámara, lo que perturba la triangulación estéreo y la estimación de profundidad.

5. APLICACIÓN

Ahora, para llevar la detección de objetos al área de la experimentación hidráulica, se probó la detección de la superficie libre de un pulso aluvional utilizando la cámara Intel RealSense D455. Para ello, se habilitó una instalación experimental en el INH (Instituto de Hidráulica), consistente en un canal cuyas dimensiones son: 4,6 metros de largo divididos en tres partes - 2,2 metros para el desarrollo del pulso aluvional, 2,0 metros con lecho móvil para medir la erosión y 0,4 metros de lecho fijo. El ancho es de 0,2 metros y la altura de 0,3 metros. Se instaló la cámara Intel RealSense D455 a 1 metro de altura, centrada en la zona del lecho móvil. En la Figura 5 se aprecia una imagen captada por la cámara. Se aplicó el mismo algoritmo para detectar el frente mediante el campo de alturas que proporciona la D455.

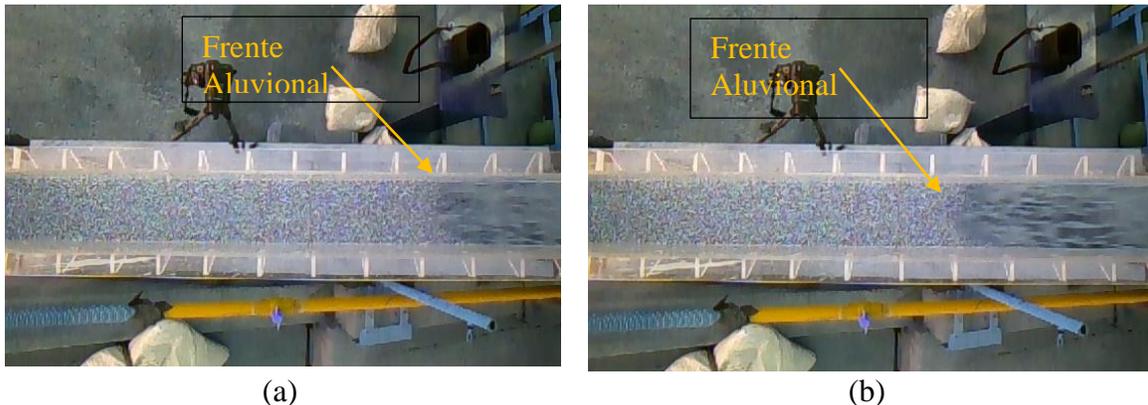


Figura 5. Fotografías obtenidas mediante la cámara D455. La dirección del flujo es de derecha a izquierda. (a) Frente aluvional en $t=0,168$ s. (b) Frente aluvional en $t=0,247$ s.

El resultado de este algoritmo en diferentes tiempos se puede observar en las Figuras 6a y 6b. En la imagen superior, se caracteriza el campo de altura del frente aluvional con los 3 perfiles longitudinales de la imagen mostrada en las Figuras 5a y 5b, respectivamente. En la imagen inferior, se muestra el promedio de los 3 perfiles longitudinales, junto con la identificación del frente simbolizado con un punto rojo. Al igual que en los casos de los objetos detallados anteriormente, se registró el avance de este punto rojo en función del tiempo, como se detalla en la Figura 7. Se observó un avance lineal, a partir del cual se pudo obtener su pendiente y, con ello, la velocidad media a la que se movía el frente.




Figura 6. La imagen superior corresponde al mapa de profundidad del pulso aluvional obtenido mediante la cámara D455 y el gráfico inferior al perfil longitudinal promedio.
 (a) Frente aluvional en $t=0,168$ s. (b) Frente aluvional en $t=0,247$ s.

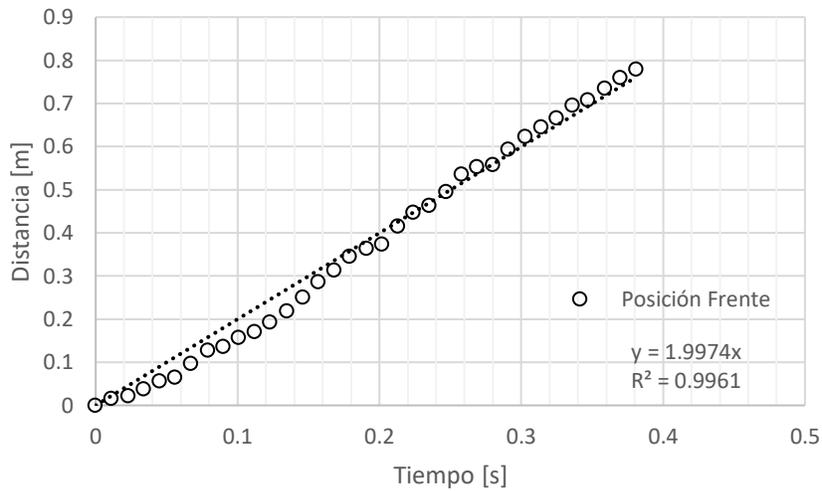


Figura 7: Curva de la posición del frente en función del tiempo para el frente aluvional.

6. CONCLUSIONES

Este estudio demostró el gran potencial de la tecnología RGB-D, y específicamente de la cámara Intel RealSense D455, para el seguimiento de objetos en movimiento y la medición precisa de velocidades en experimentos hidráulicos. La capacidad de combinar datos de color con mapas de profundidad de alta resolución permitió capturar de manera robusta el desplazamiento de diferentes objetos con formas geométricas variadas.

Sin embargo, se identificaron ciertas limitaciones relacionadas con las características geométricas de los objetos rastreados. En el caso de la pirámide, las caras inclinadas

generaron reflejos especulares que perturbaron la estimación de profundidad, introduciendo errores de hasta un 9,3% en la medición de velocidad.

Para mejorar la precisión en casos similares, se podría optimizar la configuración del sistema, ajustando la iluminación y los ángulos de visión para minimizar los reflejos indeseados. Además, se podrían explorar técnicas de procesamiento de imágenes avanzadas para combinar con la detección de la profundidad y con ello mejorar la detección de vértices y bordes en objetos con geometrías complejas.

La aplicación de esta técnica en la detección del frente de un pulso aluvional demostró su versatilidad y potencial para el monitoreo de fenómenos hidráulicos dinámicos. El seguimiento del avance del frente a partir de los datos de altura permitió obtener su velocidad media, abriendo la posibilidad de explorar otras aplicaciones en el transporte de sedimentos, flujos torrenciales y procesos con patrones de movimiento complejos.

Finalmente, se puede mencionar cómo esta tecnología llega a complementar lo que es la detección de la superficie libre 2D en el tiempo para diferentes fenómenos en la experimentación hidráulica, ya que antes de esta técnica usualmente solo se podía detectar mediante sensores puntuales (lidar, ultrasónicos, etc.) o técnicas de iluminación de perturbación de superficie libre con la limitante de no tener velocidad en el flujo.

AGRADECIMIENTOS

El autor agradece al Instituto Nacional de Hidráulica (INH) por las facilidades otorgadas para el desarrollo de este artículo. También agradece al convenio entre el INH y la Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile que permite al autor realizar los estudios para el Programa del Doctorado en Ingeniería Civil.

REFERENCIAS

- Bung, D.B., Crookston, B.M., & Valero, D. (2020). "Turbulent free-surface monitoring with an RGB-D sensor: the hydraulic jump case". *J. Hydraulic Res*, Vol. 59, No. 5, 779.
- Butkiewicz, T. (2014). Low-cost coastal mapping using Kinect v2 time-of-flight cameras. In *2014 Oceans-St. John's* (pp. 1-9). IEEE.
- Caviedes-Voullième, D., Morales-Hernández, M., López-Marijuan, I., & García-Navarro, P. (2014). Reconstruction of 2D riverbeds by appropriate interpolation of 1D cross-sectional information for flood simulation. *Environmental modelling & software*, 61, 206-228.
- Carfagni, M., Furferi, R., Governi, L., Santarelli, C., Servi, M., Ucheddu, F., & Volpe, Y. (2019). Metrological and critical characterization of the intel D415 stereo depth camera. *Sensors*, 19(3), 489.
- Ettema, R. (2000). "Hydraulic modeling: concepts and practice". *ASCE Manuals and Reports on Engineering Practice*, No. 97.
- Frostick, L.E., McLelland, S.J., Mercer, T.G. (Eds.) (2011). *Users Guide to Physical Modelling and Experimentation*. New York, CRC Press, Taylor & Francis Group.
- Frostick, L. E., Thomas, R. E., Johnson, M. F., Rice, S. P., & McLelland, S. J. (Eds.). (2017). *Users Guide to Ecohydraulic Modelling and Experimentation: Experience of the*

- Ecohydraulic Research Team (PISCES) of the HYDRALAB Network*. CRC Press, Taylor & Francis Group.
- Giancola, S., Valenti, M., Sala, R. (2018). *A Survey on 3D cameras: Metrological comparison of time-of-flight, structured-light and active stereoscopy technologies*. SpringerBriefs in Computer Science. Springer.
- Novak, P., Cabelka, J. (1981). *Models in Hydraulic Engineering: Physical Principles and Design Applications*. Pitman, London.
- Novak, P., Moffat, A.I.B., Nalluri, C., Narayanan, R. (2010). *Hydraulic structures*. CRC Press, London.
- Rouse, H., Ince, S. (1957). *History of Hydraulics*. Iowa Institute of Hydraulic Research, Pub. No. 37. También fue publicado en 1963 por Dover, New York.
- Sukhodolov, A. N. (2015). Field-based research in fluvial hydraulics: potential, paradigms and challenges. *Journal of Hydraulic Research*, 53(1), 1–19.
- Venditti, J. G., Church, M., Attard, M. E., & Haught, D. W. (2016). “Use of ADCPs for suspended sediment transport monitoring: An empirical approach”. *Water Resources Research*, 52, 2715–2736.
- Williams, R., Rennie, C., Brasington, J., Hicks, M., Vericat, D. (2015). "Hydraulic validation of two-dimensional simulations of braided river flow with spatially continuous aDcp data". *Water Resour. Res.*, Vol. 51, No. 7, pp. 5695-5716.

ACERCA DEL AUTOR

Jaime Cotroneo es Ingeniero Civil y Magister en Ciencias de la Ingeniería, mención Recursos Hídricos y Medio Ambiente de la Universidad de Chile. Actualmente es Candidato a Doctor en Ingeniería Civil en la misma casa de estudios. Durante los últimos 10 años se ha desarrollado como Ingeniero en el Instituto Nacional de Hidráulica, abarcando temáticas de modelación física y numérica en diversos ámbitos de la Hidráulica Fluvial y Transporte de Sedimentos.

ESTIMACIÓN DE LA DISTRIBUCIÓN GRANULOMÉTRICA SUPERFICIAL UTILIZANDO FOTOGRAMETRÍA Y *MACHINE LEARNING*

GERARDO ZEGERS¹, ALEX GARCÉS² Y MASAKI HAYASHI³

¹Department of Geosciences, University of Calgary, Calgary, Canadá.

gerardo.zegers@ucalgary.ca

ORCID: 0000-0002-1904-1457

²Advanced Mining Technology Center, Universidad de Chile, Santiago, Chile.

agarces@uchile.cl

ORCID: 0000-0001-9462-6167

³Department of Geosciences, University of Calgary, Calgary, Canadá.

hayashi@ucalgary.ca

ORCID: 0000-0003-4890-3113

RESUMEN

Este estudio propone un método innovador para la estimación de la distribución granulométrica superficial mediante la combinación de fotogrametría y *machine learning*. Se utilizaron imágenes captadas por un vehículo aéreo no tripulado para generar un ortomosaico de una superficie aproximada de 40 hectáreas. La metodología integra la segmentación de granos utilizando los modelos Cellpose e ImageGrains en imágenes de alta resolución (~8 mm/píxel) y la estimación de curvas granulométricas mediante el modelo SediNET en imágenes de menor resolución (~3 cm/píxel). La capacidad de aprendizaje por transferencia, presente en el modelo ImageGrains, también fue evaluado para determinar su impacto en los resultados. La recolección de datos se realizó en Fortress, Canadá, en un entorno montañoso y paraglaciar. Los resultados validan que el flujo de trabajo es escalable y eficaz para grandes extensiones de terreno, superando dificultades inherentes a los métodos tradicionales y facilitando análisis sedimentológicos en áreas de difícil acceso. Este enfoque permite obtener distribuciones granulométricas detalladas de toda el área estudiada, en lugar de limitarse a muestras puntuales como es común en las técnicas de excavación de calicatas, reduciendo significativamente el tiempo y los recursos necesarios en comparación con métodos convencionales.

Palabras claves: *Machine learning*, *transfer learning* fotogrametría dron, distribución granulométrica de sedimento en ambientes paraglaciar/periglaciares.

1. INTRODUCCIÓN

El análisis granulométrico constituye un procedimiento transversal en múltiples ciencias de la tierra como la geología, geotecnia, hidráulica, entre otros. Conocer el tamaño y tipo de

sedimento es una herramienta fundamental para entender, por ejemplo, procesos geomorfológicos y/o procesos fluviales (Riquelme et al., 2011; Ballantyne, 2002).

La curva granulométrica de una muestra de sedimentos se obtiene comúnmente a partir de una calicata donde la muestra de sedimentos es separada en fracciones de distinto tamaño por medio de tamizado mecánico. En ciertas disciplinas de ciencias de la tierra es posible observar métodos alternativos como conteo de grava o clastos en una grilla o en línea, los cuales entregan buenas aproximaciones de la curva granulométrica y permiten ser aplicados directamente en terreno (Bunte, 2001; Graham et al., 2005, 2010). Sin embargo, estos procedimientos son muy demandantes y por lo general sólo constituyen medidas puntuales respecto de la distribución granulométrica observada en un lugar. Además, el desafío de aplicar estos métodos aumenta cuando se trata de ambientes de montaña con acceso limitado.

El uso de drones en ambientes de montaña se ha popularizado debido a su gran versatilidad y facilidad de levantar información de terreno en ambientes de montaña (Garcés et al., 2021). Gracias a la técnica de aerofotogrametría y la generación de estructuras desde el movimiento (SfM, por sus siglas en inglés), un vuelo dron es capaz de registrar extensiones de terreno considerables ($\sim 1 \text{ km}^2$) con una buena resolución (3 cm/pixel) en un solo día si las condiciones climáticas lo permiten.

La generación de estos ortomosaicos de gran precisión y resolución ha motivado su uso para la caracterización de la granulometría del sedimento. Para estos usos, el análisis de imágenes para obtener granulometrías se separa en dos enfoques diferentes: tamizado por fotos y granulometría óptica. El primer enfoque busca detectar grano a grano por medio de un proceso llamado segmentación (Graham et al. 2005, Purinton and Bookhagen 2019). En consecuencia, este método requiere de un tamaño mínimo de detección para la detección correcta de los granos. El segundo enfoque en cambio estima las curvas granulométricas a través de aproximaciones estadísticas de distintas propiedades de la foto llegando incluso a una resolución sub-pixel (Buscombe, 2013).

El uso de algoritmos de *machine learning* representan una mejora significativa en el análisis de imágenes para la generación de curvas granulométricas. Siguiendo el enfoque de tamizado por fotos, Stringer et al. (2021) desarrolló Cellpose, una herramienta dedicada a la segmentación de células. Posteriormente, Mair et al. (2023) desarrolló ImageGrains a partir de Cellpose y beneficiándose del aprendizaje por transferencia para la segmentación de sedimento fluvial. Siguiendo el enfoque de granulometría óptica, Buscombe (2020) desarrolló SediNET un modelo configurable de *deep-learning* que ofrece una estimación simultánea y eficiente de múltiples percentiles de la curva granulométrica.

El presente estudio desarrolla un flujo de trabajo robusto y automatizado para la estimación de la distribución granulométrica superficial utilizando fotogrametría y *machine learning*. El flujo de trabajo se separa en tres grandes pasos: generación del ortomosaico, segmentación de granos y cálculo de curvas granulométricas en imágenes de alta resolución usando los modelos Cellpose-ImageGrains, y estimación de curvas granulométricas para toda el área de estudio utilizando SediNET en imágenes de baja resolución. Para entrenar estos algoritmos, se levantaron 40 hectáreas distintos depósitos de sedimento en Fortress, Canadá. Los

objetivos de la presente investigación son: (1) Generar un flujo de trabajo escalable para levantar la distribución granulométrica superficial de grandes extensiones de terreno. (2) Evaluar el desempeño de entrenar un algoritmo de granulometría óptica en imágenes de baja resolución a partir de datos generados por un algoritmo de tamizado por fotos en imágenes de alta resolución.

2. SITIO DE ESTUDIO

El sitio de estudio, Fortress, se ubica en las Montañas Rocosas Canadienses ($50^{\circ}49'15''$ N, $115^{\circ}13'23''$ W) en un ambiente periglacial/paraglacial (Figura 1). Los depósitos de sedimento caracterizados se encuentran dentro de un circo orientado hacia el norte en la Cordillera Frontal de este cordón montañoso. Un circo es una unidad natural de paredes abruptas, circular o semicircular que puede ser de origen glaciar o volcánico; en este caso, su origen es glaciar. La unidad más gruesa dentro del acantilado corresponde a una roca carbonatada del periodo devónico llamada Formación de Palliser (Stockmal, 1979)

En Fortress destacan las laderas de detritos y el tamaño de los granos presenta una considerable variabilidad, que va desde una "matriz abierta y gruesa con grandes espacios vacíos" hasta una "estructura soportada por clastos con todos los huecos llenos" (Christensen et al., 2020). Adicionalmente, existe una morrena cuya elevación del área varía entre los 2100 y 2500 m.s.n.m., aproximadamente. A pesar de que no se observan depósitos completamente soportados por matriz, sí existen zonas transicionales donde se mezclan clastos de gran tamaño y sedimento fino. Estas zonas transicionales se encuentran entre los depósitos de detritos en taludes del acantilado y las praderas existentes aguas abajo. Esta configuración proporciona un entorno geológico complejo y diverso para el estudio de los procesos geomorfológicos en ambientes de montaña alta.




Figura 1. (Izquierda) Levantamiento aerofotogramétrico con dron en ambiente periglacial. (Derecha) Zonas de levantamiento en el sitio de estudio Fortress

3. METODOLOGÍA

La metodología propuesta por este estudio incorpora un flujo de trabajo innovador que combina técnicas de segmentación de granos en imágenes y análisis de textura en imágenes con técnicas de fotogrametría por SfM (Figura 2). La segmentación de granos en imágenes se realiza mediante Cellpose, una herramienta avanzada diseñada para identificar granos en una fotografía y extraer sus propiedades de manera precisa. Para el análisis de textura en imágenes se emplea SediNET. La principal dificultad de los modelos de SediNET es que no proporcionan resultados satisfactorios cuando se aplican directamente debido a que SediNET no ha sido entrenado para ambientes paraglaciales y/o periglaciares. En consecuencia, este modelo debe ser entrenado con datos específicos de la zona de estudio.

La técnica de SfM, llevada a cabo en Agisoft Metashape, permite la generación de modelos de elevación digital y, a su vez, de ortomosaicos. Los levantamientos realizados consideran vuelos de baja resolución que buscan abarcar toda la zona de estudio (0.4 km²), vuelos de alta resolución en zonas específicas para la generación de distribuciones granulométricas precisas que servirán de insumo para el entrenamiento del modelo SediNET; y vuelos de ultra alta resolución que serán utilizados para la evaluación de errores y análisis de condiciones específicas. Los vuelos de baja resolución (BR) lograron resoluciones espaciales de tres centímetros, los vuelos de alta resolución (AR) resoluciones espaciales de ocho milímetros, y los vuelos de ultra alta resolución (UAR) resoluciones espaciales de dos milímetros, aproximadamente.

Esta metodología no sólo reduce las horas necesarias para el trabajo de terreno, sino que también permite el análisis de zonas que de otra manera serían inaccesibles, optimizando así los recursos y maximizando la eficiencia del estudio.

El flujo de trabajo asociado se puede subdividir en los siguientes pasos (Figura 2):

- 1) Extraer los cuadrantes AR
- 2) Segmentar cuadrantes AR usando Cellpose
- 3) Extraer propiedades de los granos con ImageGrains
- 4) Cálculo de las curvas granulométricas y diámetros característicos
- 5) Extraer los cuadrantes BR asociados a los cuadrantes AR
- 6) Entrenar y Testear SediNET
- 7) Aplicar modelo entrenado SediNET a toda el área de estudio

○ Levantamiento Dron

Para el levantamiento de imágenes dron se utilizó el sistema DJI compuesto por un Phantom 4 RTK y la antena D-RTK2. Adicionalmente, se levantaron puntos de control con un sistema D-GPS marca Leica modelo GS15 GNSS. Para poder ubicar los puntos de control en las imágenes, se distribuyeron banderas tipo tablero de ajedrez a lo largo de la zona de estudio.

El dron utilizado posee la capacidad de seguir una ruta preestablecida, la cual se programa en función de un modelo de elevación digital. Esta característica posee la crucial ventaja de

mantener la resolución de muestreo constante a pesar de las variaciones de cota del terreno. El modelo de elevación digital utilizado para la programación de los vuelos corresponde a la topografía satelital ALOS PALSAR (12.5×12.5 m JAXA/METI ALOS PALSAR L1.0 2007).




Figura 2. Flujo de trabajo para el entrenamiento de las herramientas de *machine learning* utilizadas para la estimación de la distribución granulométrica superficial.

Los vuelos de baja resolución se hicieron con una altura de vuelo objetivo de 100 metros respecto del suelo. Se tomaron un total de 740 imágenes traslapadas 80% en horizontal y vertical, las cuales cubren toda el área de estudio y permiten extraer las distribuciones granulométricas. Por otra parte, los vuelos de alta resolución se volaron con una altura objetivo de 30 metros respecto del suelo y con traslapos de 90% horizontal y vertical. Las imágenes de alta resolución son cruciales para la técnica de tamizado por imágenes. Finalmente, los vuelos de ultra alta resolución variaron entre 7.6 y 12 metros respecto del suelo. Si bien la mayoría de las imágenes fueron capturadas con la cámara mirando en 90 grados hacia abajo (nadir), se testeó también la herramienta de vuelo que observa el terreno perpendicularmente a un plano inclinado que es trazado con el mismo vuelo dron.

Las imágenes BR se subdividieron en cuadrantes de 340×340 píxeles, lo cual, entrega extensiones de $10 \text{ m} \times 10 \text{ m}$, dependiendo de la resolución específica del ortomosaico. Por el contrario, las imágenes AR se subdividieron en cuadrantes de $\sim 1200 \times \sim 1200$ píxeles para cubrir las mismas extensiones de los cuadrantes BR.

Los levantamientos dron se realizaron en modo *real time kinematic* (RTK), lo cual ofrece una precisión al centímetro del levantamiento. Sin embargo, la antena base fue configurada como punto autónomo y no se amarró a ninguna red geodésica. Lo anterior resulta en que distintos levantamientos pueden quedar desalineados en distancias del orden de metros. Para solucionar tal problema, se utilizó la herramienta de coregistración de Shean et al. (2016). Los levantamientos AR se alinearon utilizando como base el ortomosaico BR.

Los ortomosaicos resultantes son utilizados para medir el tamaño del sedimento, es decir, para medir distancias a partir del tamaño de los píxeles. Para poder evaluar el error asociado a la medición de distancias en los levantamientos, se compararon distancias medidas entre banderas en el ortomosaico y distancias según el levantamiento D-GPS. Por lo tanto, el error asociado a medición de distancias (σ_{Dist}) se calcula según la Ec. (1).

$$\sigma_{Dist} = \frac{DO_{ij} - DR_{ij}}{DR_{ij}} \quad (1)$$

Donde DO_{ij} es la distancia entre la bandera i y la bandera j medida en el ortomosaico, mientras que DR_{ij} corresponde a la distancia de referencia entre las mismas banderas medida por el D-GPS Leica. Los errores obtenidos para σ_{Dist} variaron entre 0.07% y 0.3% lo cual demuestra la gran precisión que la fotogrametría por medio de un dron en modo RTK es capaz de lograr.

3.1 Segmentación de Imágenes y extracción de GSD.

Para la segmentación de imágenes se utilizó la herramienta Cellpose, mientras que para la extracción de las propiedades de los granos se utilizó ImageGrains. Cellpose fue desarrollado originalmente para la detección de células (Stringer et al., 2021; Pachitariu and Stringer, 2022). Posteriormente, Cellpose fue utilizado por Mair et al. (2023), quienes desarrollaron ImageGrains para extraer las propiedades de sedimento fluvial. Mair et al. (2023) demostró que, gracias a su propiedad de aprendizaje por transferencia, ImageGrains aprovecha las capacidades entrenadas para detectar células, en su entrenamiento para detectar sedimento fluvial. En consecuencia, en este estudio evalúa el efecto que tiene el aprendizaje por transferencia en el entrenamiento de ImageGrains para detectar sedimento de ambientes periglaciares/paraglaciares. Para esto, se analizan los resultados utilizando los modelos:

- **Fs**: corresponde al modelo entrenado por Mair et al. (2023) para la detección de sedimento fluvial.
- **noAT**: corresponde al modelo entrenado sólo con datos de Fortress y por lo tanto no se beneficia del aprendizaje por transferencia.
- **AT_Fs**: corresponde al reentrenamiento del modelo Fs utilizando datos de Fortress y por lo tanto sí se beneficia del aprendizaje por transferencia.

Las curvas granulométricas obtenidas mediante tamizado mecánico relacionan el tamaño de las partículas y su masa. Para obtener curvas granulométricas a partir del análisis de imágenes, es necesario estimar el volumen asociado a una partícula. Sin embargo, de las imágenes sólo se extrae pueden extraer propiedades como el área del grano proyectado, y los ejes mayor y menor. Para la estimación del volumen de las partículas se utilizó la siguiente expresión propuesta por Ibbeken y Schleyer (1986):

$$V = \frac{2}{3} A d_b \quad (2)$$

Donde A representa el área de la partícula segmentada y d_b su eje menor. Las mediciones de A y d_b se convierten de píxeles a unidades métricas basándose en la resolución específica de cada imagen. Se calculan las distribuciones granulométricas usando la escala ϕ y diámetros característicos como D_{10}^* , D_{16}^* , D_{50}^* , D_{84}^* , D_{90}^* , empleando la notación D_X^* para representar percentiles específicos de la fracción gruesa (>3 cm) y evitar confusiones con distribuciones granulométricas integrales. Para asegurar precisión de este método, se excluyen partículas cuyo eje d_b exceda los 2.5 metros o que constituyan más del 25% del peso de la muestra debido a que no se consideran representativos de la muestra.

3.2 SediNET

SediNET fue desarrollado por Buscombe (2020) para estimar una serie de propiedades sedimentológicas, las cuales pueden ser propiedades continuas (como la textura) o categorizadas. A diferencia de Cellpose e ImageGrains, SediNET no posee la capacidad de aprendizaje por transferencia, por lo que este modelo es entrenado desde cero.

4. RESULTADOS

4.1 Segmentación y curvas granulométricas en imágenes AR

4.1.1 Desempeño del proceso de segmentación

El desempeño de Cellpose se mide mediante la métrica de Intersección sobre Unión (IoU, por sus siglas en inglés), empleada por Stringer et al. (2021) para evaluar las predicciones de Cellpose contra segmentaciones manuales de sedimento. Para clasificar un objeto como correctamente segmentado, se establece un umbral de IoU en 0.5. Este procedimiento identifica los verdaderos positivos (VP), que son los granos correctamente detectados por Cellpose; los falsos positivos (FP), que son granos inexistentes detectados erróneamente por Cellpose como existentes; y los falsos negativos (FN), que son granos existentes que Cellpose no logró detectar. Finalmente, el rendimiento de Cellpose se cuantifica mediante la precisión promedio (PP) especificada en la Ec. (3).

$$PP = \frac{VP}{VP + FP + FN} \quad (3)$$

La Figura 3 muestra que el modelo ImageGrains, Fs, no entrenado en el conjunto de datos actual, tuvieron el peor desempeño. Mientras que el modelo entrenado con sedimento específico de Fortress pero sin aprendizaje por transferencia “noAT” logra un mejor

desempeño. Por lo tanto, modelos entrenados para segmentar células, ni tampoco un modelo entrenado para segmentar sedimento fluvial es capaz de reconocer el tipo de sedimento observado en ambientes perilaciares/paraglaciares. Esto deja en evidencia la importancia de entrenar el modelo con el tipo de sedimento correcto que se desea caracterizar. Los modelos AT_Fs que sí fueron entrenados con datos del sitio de estudio y, además, emplearon aprendizaje por transferencia, alcanzaron la mayor precisión. Esto demuestra el aporte del aprendizaje por transferencia en mejorar el desempeño general del modelo.




Figura 3. Desempeño del proceso de segmentación. La línea celeste representa el rendimiento de imágenes individuales, mientras que las líneas rojas representan la precisión promedio que se calcula sobre los mosaicos de entrenamiento o testeo. El área sombreada representa una desviación estándar.

En todos los casos se obtuvo una precisión promedio similar para los casos de entrenamiento y testeo, indicando que los modelos generan una generalización de datos robusta. Esto implica que los modelos han aprendido con éxito a extraer características significativas para predecir los diámetros característicos en lugar de simplemente ajustarlos a las características específicas de los datos de entrenamiento. Tal generalización es crucial para un rendimiento confiable en nuevas imágenes y conjuntos de datos diversos.

4.1.2 Exactitud de las curvas granulométricas en imágenes AR

Para poder evaluar el error asociado a la generación de curvas granulométricas mediante tamizado por fotos, se propone calcular el error según la Ec. (4) de cada diámetro característico generado a partir de la curva granulométrica.

$$\sigma_{CI}^{D*i} = \frac{1}{N} \sum_{j=1}^N \left| \frac{D(j)_i^{*ref} - D(j)_i^{*pred}}{D(j)_i^{*ref}} \right| \cdot 100 \quad (4)$$

Donde $D(j)_i^{*ref}$ es el i -ésimo diámetro característico de referencia obtenido a partir de las imágenes segmentadas manualmente, mientras que $D(j)_i^{*pred}$ es su análogo, pero predicho por Cellpose-ImageGrains. N es el número de imágenes utilizadas. Para este análisis fue necesario determinar un umbral de corte de píxeles, para el cual tamaños de granos que queden por debajo de este número de píxeles quedan excluidos de la detección.

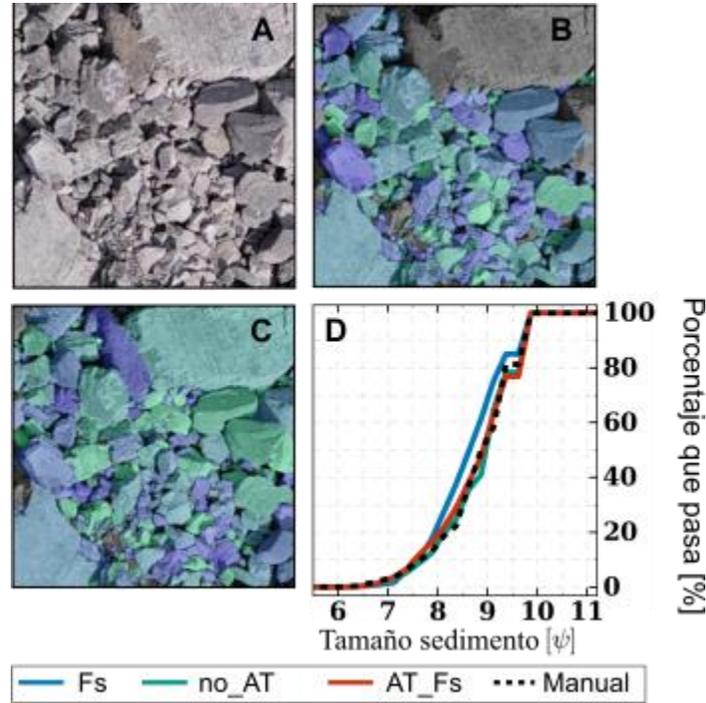


Figura 4. Comparación de la segmentación manual y la segmentación hecha por Cellpose-ImageGrains. A) cuadrante extraído del ortomosaico, B) segmentación de Cellpose-ImageGrains, C) Segmentación manual, D) curvas granulométricas para los tres modelos de segmentación.

La Figura 4 presenta los resultados de segmentación del modelo AT_Fs (panel B) comparados con el procedimiento de segmentación manual (panel C). Adicionalmente, las distribuciones granulométricas por medio de los tres modelos de segmentación se presentan en la Figura 4.D. Basado en los resultados de la Figura 3, como era de esperar, el modelo Fs resulta en la distribución granulométrica más disímil respecto de la segmentación manual. En cambio, las distribuciones granulométricas calculadas con los modelos entrenados con el conjunto de datos de Fortress (no_AT y AT_Fs) coinciden estrechamente con las distribuciones granulométricas manuales. Esta figura destaca la gran capacidad de segmentación del modelo AT_Fs, que representa con precisión la mayoría de los granos presentes.

El modelo Fs presenta errores que van de 11% a 28%, mientras que los modelos entrenados con datos de Fortress reducen drásticamente su error a rangos entre 5% y 9% (Tabla 1). En

el caso del modelo más entrenado, AT_Fs, el error tiende a crecer con el aumento de diámetro característico. Esto tiene sentido si se considera la mayor sensibilidad de la curva granulométrica a los granos más grandes de la muestra donde un solo bloque puede significar un porcentaje relevante del peso total de la muestra. A modo de ejemplo, se observa en la Figura 4.B que la roca de mayor tamaño en la imagen posee un tamaño considerable.

Tabla 1. Error σ_{CI}^{D*i} de los modelos Cellpose-ImageGrains entrenados para la segmentación de granos en fotos AR.

	Fs	noAT	AT_Fs
σ_{CI}^{D*10} [%]	27.6	5.7	4.7
σ_{CI}^{D*16} [%]	25.0	4.9	5.2
σ_{CI}^{D*50} [%]	15.7	8.5	6.8
σ_{CI}^{D*84} [%]	13.2	8.7	8.4
σ_{CI}^{D*90} [%]	11.4	7.1	7.4
Promedio [%]	18.6	7.0	6.5

4.1.3 Tamaño mínimo de detección.

Los métodos de segmentación de imágenes utilizan un umbral de píxeles que debe ser definido por el usuario. El tamaño mínimo detectable (TMD) varía normalmente entre 12 y 20 píxeles. Con el objetivo de obtener más información de los análisis de imágenes, se exploró la posibilidad de usar un valor de corte de píxeles más bajo sin comprometer la precisión de la estimación. Para poder calcular errores de las imágenes AR, se debió realizar vuelos de ultra alta resolución (UAR) que alcanzaron resoluciones de 2 mm/píxel. Estas imágenes se subdividieron en cuadrantes de 2000×2000 píxeles y fueron remuestreadas a la mitad de su resolución para obtener cuadrantes de 1000×1000 . Para el cálculo de estos errores se seleccionó el modelo TF_Fs, el cual demostró, en las secciones anteriores de este trabajo, ser el modelo con mejores resultados. De esta manera, se calculó el error asociado a un umbral de corte de i píxeles (Px^i) según la Ec. (5).

$$Px_{error}^i = \left| \frac{Dref *_{10}^{2i} - D *_{10}^i}{Dref *_{10}^{2i}} \right| \quad (5)$$

Donde $Dref *_{10}^{2i}$ es el tamaño característico del sedimento calculado en los cuadrantes de 2000×2000 píxeles para el cual el 10% de la muestra es inferior a dicho valor. $Dref *_{10}^i$ corresponde a su tamaño característico análogo al anterior pero calculado a partir de los cuadrantes de 1000×1000 píxeles. Para cuadrar los tamaños de ambas resoluciones, la cantidad de píxeles i de TMD en los cuadrantes de 1000×1000 equivalen a $2i$ píxeles en los cuadrantes de 2000×2000 píxeles.

La Figura 5 muestra la variación del error Px_{error}^i para distintos valores de TMD que van de 5 a 14 píxeles. Como se esperaba, el error promedio disminuye a medida que aumenta el valor de TMD. De este gráfico se observa una importante disminución del error hasta los 8

pixeles, mientras que la reducción se vuelve más gradual hasta alcanzar su valor mínimo en aproximadamente 13 pixeles.

Es notable que hay una disminución sustancial en el error de PxC hasta un valor de 8, después del cual la reducción se vuelve más gradual, sin una disminución significativa en el error promedio de PxC hasta alcanzar un valor de entre 12 y 13. Por esta razón, se decidió trabajar con 8 pixeles como TMD.




Figura 5. Error de detección en función del tamaño mínimo de detección (TMD) en número de pixeles

4.2 SediNET en imágenes BR

4.2.1 Desempeño del modelo SediNET

El modelo SediNET fue entrenado utilizando conjuntos de lotes de 10, 20 y 30, con una tasa de abandono del 0.25, a lo largo de 300 épocas. Estos parámetros fueron seleccionados para optimizar el rendimiento de SediNET. Del conjunto de datos, se seleccionó un 80% de la muestra como conjunto de entrenamiento y el 20% restante para testeo. Para evaluar el desempeño de SediNET se utilizó el error de la Ec. (6)

$$\sigma_S^{D*i} = \frac{1}{N} \sum_{j=1}^N \left| \frac{D(j)_i^{*CI} - D(j)_i^{*pred}}{D(j)_i^{*ref}} \right| \cdot 100 \quad (6)$$

Los resultados del modelo entrenado SediNET se presentan en la Figura 6, donde visualmente ya se puede evidenciar la buena relación 1:1 entre los valores observados y predcidos por SediNET. Los errores obtenidos a partir de la Ec. (6) también se presentan en la figura. Se observa que los menores errores se obtienen para los diámetros característicos más grandes, lo cual puede estar relacionado con la facilidad de detectar granos de mayor tamaño en imágenes de baja resolución.




Figura 6. Desempeño del modelo SediNET entrenado a partir de las curvas granulométricas generadas por modelo AT_Fs.

4.2.2 Distribución granulométrica superficial de Fortress

Finalmente, el algoritmo SediNET entrenado puede ser aplicado a toda la extensión del ortomosaico para obtener la distribución granulométrica de cada cuadrante (Figura 7). A modo de ejemplo, la figura 7 presenta la distribución espacial del diámetro característico D_{10} , sin embargo, estos mapas pueden ser generados para todos los diámetros característicos generados en la Figura 6. La selección del diámetro característico a presentar dependerá del fenómeno que se desee estudiar. Para facilitar la comparación visual de lo observado en el ortomosaico y el resultado de cada cuadrante, se presentan también 3 zonas específicas.




Figura 7. Distribución granulométrica superficial de Fortress. Los paneles A y B presentan las zonas de levantamiento y el ortomosaico resultante. Los paneles C y D presentan el resultado del algoritmo SediNET para el caso del diámetro característico D_{10} . Se presentan además 3 zonas específicas para facilitar la comparación visual de los resultados

4.3 Error total de la estimación

Para cada uno de los tres pasos del flujo de trabajo se han estimado sus errores asociados. A partir de la aerofotogrametría y la generación de ortomosaicos con SfM se obtuvo el error σ_{Dist} (Ec. 1). En las imágenes AR, el proceso de segmentación y extracción de curvas granulométricas utilizando Cellpose-ImageGrains tiene el error asociado σ_{CI}^{D*} (Ec. 4). En las imágenes BR, el entrenamiento y testeo de SediNET con los datos de Fortress entregaron el error σ_S^{D*} (Ec. 6). En consecuencia, el error total asociado a la estimación de la distribución granulométrica superficial está dado por la Ec. (7)

$$\sigma_{\text{método}} = (1 + \sigma_{\text{Dist}})(1 + \sigma_{\text{CI}}^{D*})(1 + \sigma_{\text{CI}}^{D*}) - 1 \quad (7)$$

Tomando los valores promedio de cada uno de estos errores, se obtiene que el error promedio del método es $\sigma_{\text{método}} = 18.9\%$.

5. DISCUSIÓN

Los modelos Cellpose-ImageGrains resultaron en errores crecientes a medida que el tamaño característico de sedimento crece. Por el contrario, SediNET resultó en errores decrecientes a medida que el tamaño característico del sedimento crece. Este comportamiento contradictorio de ambos métodos puede deberse al enfoque metodológico de ambos métodos. Cellpose utiliza un enfoque de tamizado por fotos, mientras que SediNET funciona a través de granulometría óptica, lo cual se basa en análisis estadísticos como por ejemplo análisis de variaciones de intensidad y color dentro de imágenes bidimensionales (2D) y tridimensionales (3D) (Buscombe, 2013; Lang et al., 2020). Por otra parte, Cellpose-ImageGrains utilizan imágenes de alta resolución, mientras que SediNET trabaja con las imágenes de baja resolución.

El error asociado al flujo de trabajo propuesto puede parecer alto ($\sigma_{\text{método}} = 18.9\%$). Sin embargo, el aumento de la cobertura espacial para conocer la distribución granulométrica de grandes extensiones de terreno es inigualable. Métodos tradicionales como tamizado mecánico por lo general están restringidos mediciones puntuales como por ejemplo calicatas de 1 m², lo cual resulta en trabajo muy demandante en costo y tiempo. Por otra parte, el tamizado mecánico está más expuesto a errores metodológicos por lo que debe ser supervisado rigurosamente.

6. CONCLUSIONES

El presente trabajo detalla un flujo de trabajo desarrollado para estimar la distribución granulométrica superficial utilizando fotogrametría y *machine learning*. El estudio se beneficia de las técnicas:

- 1) Aerofotogrametría dron: capaz de levantar la información necesaria en áreas extensas (hasta ~1km² por día con un Phantom 4 RTK).
- 2) Tamizado por fotos: gracias al entrenamiento de modelos Cellpose-ImageGrains se obtiene la distribución granulométrica de imágenes de alta resolución en sectores específicos que generan el conjunto de datos de alta resolución.
- 3) Granulometría óptica: gracias al entrenamiento del modelo SediNET, las curvas granulométricas obtenidas del paso anterior son escalables a grandes extensiones de levantamiento manteniendo bajo sus requerimientos computacionales.

Las comparaciones de desempeño de los modelos Cellpose-ImageGrains, los cuales poseen un enfoque de tamizado por fotos, dejan en evidencia que un modelo entrenado para detectar sedimento fluvial es incapaz de detectar correctamente el tipo de sedimento observado en ambientes paraglaciar/periglaciares. Gracias al conjunto de datos generados para Fortress,

el modelo entrenado para el sitio de estudio obtuvo un buen desempeño para la segmentación y extracción de curvas granulométricas en imágenes de alta resolución.

El análisis realizado para el tamaño mínimo de detección fue crucial para entender cómo este parámetro afecta en la propagación del error asociado a la segmentación de granos en imágenes. Si bien la literatura recomienda valores sobre los 12 píxeles, el análisis presentado aquí, permitió bajar este número a 8 píxeles sin grandes impactos en los errores asociados. Esta diferencia permite que para la misma resolución de imágenes se logren detectar menores tamaños de sedimento.

El modelo SediNET demostró su capacidad de ser usado en grandes extensiones de terreno. Sin embargo, el principal desafío de SediNET radica en que éste debe ser entrenado con datos específicos de la zona de estudio si se quiere lograr la precisión alcanzada en este estudio. En consecuencia, queda abierta la pregunta si con un mayor conjunto de datos el modelo es generalizable a ambientes periglaciares/paraglaciares o si es necesario entrenar el modelo para cada sitio de estudio. Se espera poder responder esta pregunta en futuras investigaciones.

Por medio de una propagación de errores, se determinó que el error promedio del método es de 19%. Si bien este valor puede parecer alto, se debe tener en cuenta que el tamaño de los sedimentos caracterizados puede ir de los pocos centímetros hasta bloques del orden de los metros (>2 órdenes de magnitud). Por otra parte, considerando las ventajas de este método en cuanto a la facilidad de volar un dron sobre terrenos de difícil acceso y la extensión del área caracterizada, este método supera con creces la capacidad de caracterización de las mediciones puntuales como es el caso de una calicata de un metro cuadrado y su tamizado mecánico.

AGRADECIMIENTOS

Los autores agradecen al centro investigación para la minería (AMTC) y al proyecto ANID-PIA AFB230001. Gerardo Zegers y Alex Garcés agradecen el financiamiento de las becas de doctorado ANID 72200390 and 21191593, respectivamente.

REFERENCIAS

- Ballantyne, C.K. (2002) Paraglacial geomorphology. *Quaternary Science Reviews*, 21(18-19), 1935–2017. doi: 10.1016/S0277-3791(02)00005-7.
- Bunte, K. (2001) Sampling surface and subsurface particle-size distributions in wadable gravel- and cobble-bed streams for analyses in sediment transport, hydraulics, and streambed monitoring. US Department of Agriculture, Forest Service, Rocky Mountain Research Station.
- Buscombe, D. (2013) Transferable wavelet method for grain-size distribution from images of sediment surfaces and thin sections, and other natural granular patterns. *Sedimentology*, 60(7), 1709–1732. doi:10.1111/sed.12049.

- Buscombe, D. (2020) SediNet: a configurable deep learning model for mixed qualitative and quantitative optical granulometry. *Earth Surface Processes and Landforms*, 45(3), 638–651. doi:10.1002/esp.4760.
- Christensen, C.W., Hayashi, M. & Bentley, L.R. (2020) Hydrogeological characterization of an alpine aquifer system in the Canadian Rocky Mountains. *Hydrogeology Journal*, 28(5), 1871–1890. doi:10.1007/s10040-020-02153-7.
- Garcés, A., A. Cabré, G. Aguilar, A. Tamburrino & S. Montserrat (2021). Caracterización de la evolución geomorfológica de sistemas fluviales mediante el uso de dron. XXV Congreso Chileno de Ingeniería Hidráulica. Santiago, Chile. 2 13-15 de octubre.
- Graham, D.J., Reid, I. & Rice, S.P. (2005) Automated sizing of coarse-grained sediments: image-processing procedures. *Mathematical geology*, 37, 1–28.
- Graham, D.J., Rollet, A.J., Piégay, H. & Rice, S.P. (2010) Maximizing the accuracy of image-based surface sediment sampling techniques. *Water Resources Research*, 46(2).
- Ibbeken, H. & Schleyer, R. (1986) Photo-sieving: A method for grain-size analysis of coarse-grained, unconsolidated bedding surfaces. *Earth Surface Processes and Landforms*, 11(1), 59–77. doi:10.1002/esp.3290110108.
- Lang, N., Irniger, A., Rozniak, A., Hunziker, R., Wegner, J.D. & Schindler, K. (2020) GRAINet: Mapping grain size distributions in riverbeds from UAV images with convolutional neural networks. *Hydrology and Earth System Sciences Discussions*, 1–38. doi:10.5194/hess-2020-196.
- Mair, D., Witz, G., Do Prado, A.H., Garefalakis, P. & Schlunegger, F. (2023) Automated detecting, segmenting and measuring of grains in images of fluvial sediments: The potential for large and precise data from specialist deep learning models and transfer learning. *Earth Surface Processes and Landforms*, doi:10.1002/esp.5755.
- Pachitariu, M. & Stringer, C. (2022) Cellpose 2.0: how to train your own model. *Nature Methods*, 19(12), 1634–1641. doi:10.1038/s41592-022-01663-4.
- Purinton, B. & Bookhagen, B. (2019) Introducing PebbleCounts: A grain-sizing tool for photo surveys of dynamic gravel-bed rivers. *Earth Surface Dynamics*, 7(3), 859–877. doi:10.5194/esurf-7-859-2019.
- Riquelme, R., Rojas, C., Aguilar, G. & Flores, P. (2011) Late Pleistocene-early Holocene paraglacial and fluvial sediment history in the Turbio valley, semiarid Chilean Andes. *Quaternary Research*, 75(1), 166–175. doi:10.1016/j.yqres.2010.10.001.
- Shean, D.E., Alexandrov, O., Moratto, Z.M., Smith, B.E., Joughin, I.R., Porter, C. et al. (2016) An automated, open-source pipeline for mass production of digital elevation models (DEMs) from very-high-resolution commercial stereo satellite imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 101–117. doi:10.1016/j.isprsjprs.2016.03.012.
- Stockmal, G.S. (1979) Structural geology of the northern termination of the Lewis Thrust, Front Ranges, southern Canadian Rocky Mountains. Master thesis, University of Calgary, Calgary, Canada.
- Stringer, C., Wang, T., Michaelos, M. & Pachitariu, M. (2021) Cellpose: a generalist algorithm for cellular segmentation. *Nature Methods*, 18(1), 100–106. doi:10.1038/s41592-020-01018-x.

Westoby, M.J., Dunning, S.A., Woodward, J., Hein, A.S., Marrero, S.M., Winter, K. et al. (2015) Sedimentological characterization of Antarctic moraines using UAVs and Structure-from-Motion photogrammetry. *Journal of Glaciology*, 61(230), 1088–1102. doi:10.3189/2015JoG15J086.

ACERCA DE LOS AUTORES

Gerardo Zegers es Ingeniero Civil y Magíster en Ciencias de la Ingeniería, mención Recursos y Medio Ambiente Hídrico de la Universidad de Chile. Actualmente es estudiante de Doctorado en el Departamento de Ciencias de la Tierra de la Universidad de Calgary, Canadá. Sus áreas de investigación son el permafrost y la hidrogeología de montaña.

Alex Garcés es Ingeniero Civil y Magíster en Ciencias de la Ingeniería, mención Recursos y Medio Ambiente Hídrico de la Universidad de Chile, estudiante del Programa de Doctorado en Fluidodinámica de la Universidad de Chile, e Investigador Asociado del Advanced Mining Technology Center (AMTC), Universidad de Chile. Sus áreas de interés son el transporte hidráulico de sólidos, en especial la amenaza aluvional, junto con la modelación numérica y física de estos fenómenos.

Masaki Hayashi es Magíster en Ciencias de la Universidad de Chiba, Japón, y Doctor en Ciencias de la Tierra de la Universidad de Waterloo, Canadá. Es profesor del Departamento de Geociencias en la Universidad de Calgary. Sus áreas de investigación son la hidrología alpina, el permafrost, la hidrología de suelos congelados y en praderas, así como otros temas relacionados

HIDRO-GRAFÍA

ALDO TAMBURRINO TAVANTZIS



La Hidro-Grafía de este número fue extraída del frontispicio de un libro publicado en 1678 y corresponde a:

- a) El boceto de una fuente diseñada por Luigi Vanvitelli, en el que por primera vez se determina la altura que alcanzarán los chorros de agua en una fuente utilizando la ecuación de Bernoulli.
- b) Una representación de una ballena como un monstruo acuático. La grasa obtenida de ella era usada como impermeabilizante en las uniones de sistemas de conducción de agua.
- c) Una alegoría de un modelo del ciclo hidrológico en el que el agua del mar vuelve a la tierra, elevándose sobre ella para formar ríos y volver al mar.

NÚMERO ANTERIOR

La respuesta correcta a la HIDRO-GRAFÍA del número anterior es la alternativa b): La planta está relacionada etimológicamente con los fluidos viscosos.

Corresponde a una página de *Hortus Sanitatis* (El Jardín de la Salud), una enciclopedia de ciencias naturales, de autor desconocido y publicada en 1491 en Maguncia (Mainz), Alemania por Jacob Meydenbach. Escrita en latín, describe especies vegetales, incluyendo sus usos medicinales, además de animales, minerales y seres míticos como el dragón, fénix, etc. En la figura se presenta el Capítulo 491 de la sección de Hierbas en la que se describe el *viscum*, (muérdago), planta semiparásita que crece en las ramas de ciertos árboles y cuyo fruto es una baya que contiene la semilla en una pulpa pegajosa (o viscosa). De *viscum* deriva la palabra viscosidad, que caracteriza la propiedad de fluir que tienen los fluidos.



INVITACION A CONTRIBUIR CON ARTÍCULOS

La Revista de la Sociedad Chilena de Ingeniería Hidráulica invita a contribuir con artículos para ser publicados en sus próximos números. Los artículos pueden ser en castellano o inglés.

Los artículos buscan difundir trabajos en el área de interés de la Sociedad Chilena de Ingeniería Hidráulica, especialmente aquellos relativos a la hidráulica, hidrología y mecánica de fluidos en general, así como otros aspectos relacionados con el agua, como su uso, gestión, recursos, tecnologías, historia, etc. Los artículos pueden ser de investigación teórica o aplicada, soluciones novedosas a problemas de ingeniería, difusión u otros temas de interés para la comunidad hidráulica nacional.

El formato de presentación de los trabajos puede solicitarse al Editor a la dirección electrónica atamburr@uchile.cl

