

## ANÁLISIS DE CALIDAD DE ARENAS DE FRACTURACIÓN MEDIANTE VISIÓN ARTIFICIAL Y REDES NEURONALES

Mg. Ing. Carlos Gustavo Rodriguez Medina <sup>1</sup>, Dr. Ing. Oscar Daniel Chuk <sup>2</sup>,  
Lic. Adriana Luna, Ing. Regina Bertero, Ing. Enrique Núñez.

Instituto de Investigaciones Mineras / Facultad de Ingeniería /  
Universidad Nacional de San Juan

Av. Libertador Gral. San Martin 1109 oeste. San Juan  
0264-4211700 (int. 285 <sup>1</sup>, int. 389 <sup>1,2</sup>)

grodriguez@unsj.edu.ar <sup>1</sup>, dchuk@unsj.edu.ar <sup>2</sup>

### RESUMEN

La fracturación hidráulica realizada para extraer hidrocarburos de yacimientos no convencionales requiere de la inyección de arenas que actúan como apuntalantes de la fractura. La calidad de las arenas para cumplir dicha función se evalúa por la norma API19C, que establece medidas geométricas – esfericidad y redondez- más un porcentaje de fractura cuando la muestra es sometida a compresión. Todas estas mediciones deben encontrarse dentro de valores límites para asegurar la calidad de la arena.

Según la norma, la inspección se realiza visualmente por un operador sobre un conjunto de 20 granos. Esto introduce un importante grado de subjetividad, y poca validez estadística. Para solucionar esto, la bibliografía refiere distintos métodos basados en visión artificial. Cada uno de estos métodos tiene ventajas y desventajas según la geometría, color de la partícula y la definición de la imagen usada.

En este trabajo se presenta una metodología integrada a partir de varios métodos conocidos, más uno novedoso desarrollado por los autores para medir la redondez, que es la variable más difícil de medir. Las distintas medidas son tratadas por redes neuronales para dar una medida final de la redondez, que tiene un alto grado de correlación con la

medida teórica de cada partícula considerada. Las medidas de esfericidad y porcentaje de fractura obtenidas también han dado valores consistentes.

El método de visión artificial desarrollado es sumamente eficiente para determinar, a partir de las medidas obtenidas, la capacidad de una arena para actuar como apuntalante en una operación de fractura hidráulica.

**Palabras clave:** Visión artificial, Redes neuronales, Fracturación hidráulica, Arenas, geometría.

### CONTEXTO

Este trabajo presenta de manera resumida parte de los avances y resultados del Proyecto de Desarrollo Tecnológico y Social (PDTS – UNSJ) “*Desarrollo de un algoritmo de análisis de calidad de arenas de fracturación basado en visión artificial*”, como así también del Proyecto de Investigación Científica (PIC – UNSJ) “*Clasificación de partículas de arena de fracturación mediante redes neuronales convolucionales*”, ambos en ejecución durante el periodo 2020 – 2022.

Tales proyectos se inscriben dentro de la línea de investigación que lleva adelante un grupo de trabajo en la temática de Inteligencia y Visión Artificial orientado al control automático de procesos mineros, en el

Instituto de Investigaciones Mineras de la Facultad de Ingeniería de la UNSJ.

## 1. INTRODUCCIÓN

Para que las partículas de arena utilizadas en fracturación hidráulica (fracking) actúen apropiadamente como apuntalante o “propante”, deben resistir las altas presiones usadas en el proceso, del orden de los 10.000 psi. Esta capacidad es clave para el éxito del proceso. Para determinar la resistencia de la arena, se reconocen como base las normas del American Petroleum Institute API RP 19 B, la cual define un ensayo a la compresión para determinar el porcentaje de fractura. Pero también son de rigor, según la norma API 19C [1], el análisis de distribución granulométrica y, fundamentalmente, las medidas geométricas de redondez y esfericidad. Éstas últimas son definitorias pues si no superan un valor de 0.6 (ambas medidas oscilan entre 0 y 1), la arena es descartada.

Según las normas citadas, la determinación de la redondez y esfericidad recae en la observación de 20 granos tomados al azar por parte de un operador, por asimilación a las imágenes de una cartilla de referencia propuesta por Krumbein y Sloss [2]. Estos autores desarrollaron sus medidas en base a las expresiones de Wadell [3] [4] [5], pero la aplicación de sus fórmulas es muy complicada en la práctica; de allí la generación de la cartilla y la intervención de un observador humano. Esta metodología padece de una fuerte dependencia del criterio de dicho observador, lo cual deriva en resultados sustancialmente disímiles que invalidan el procedimiento, aunque es el que se sigue por norma.

El uso de la visión artificial es una alternativa poderosa para lograr una medida objetiva de las propiedades geométricas de partículas, de lo cual Rodríguez [6] presenta una detallada revisión del estado del arte.

La bibliografía existente cubre la determinación de la distribución granulométrica [7], como así también esfericidad [8] y la redondez [9]-[10], sin

dejar de lado otros indicadores como el factor de forma, la concavidad y la convexidad [11]. Entre todas las medidas detalladas, la redondez es la que es más susceptible de error por la apreciación humana. Esto ha llevado por un lado a intentar medir esta propiedad por técnicas estrictamente geométricas. Rodríguez et al. [13] registran 19 formas distintas de medir la redondez con esta perspectiva.

Por otro lado, se han aplicado técnicas indirectas para determinar la redondez usando como datos de entrenamiento de un algoritmo estimador una serie de mediciones previamente hechas con algún criterio de los citados en el párrafo anterior. Sun [14], por ejemplo, utiliza un algoritmo de optimización de enjambre de partículas para calcular la redondez.

Se presenta en este artículo un abordaje combinado para la determinación de la redondez. Dado que los distintos métodos adolecen de ciertos problemas en determinadas circunstancias, las mediciones logradas por métodos tradicionales más dos desarrolladas por los autores se combinan en entradas de distintas redes neuronales para rescatar lo mejor de cada procedimiento y dar un resultado final confiable.

## 2. LINEAS DE INVESTIGACIÓN Y DESARROLLO

En el Laboratorio de Control Automático del Instituto de Investigaciones Mineras (Facultad de Ingeniería de la Universidad Nacional de San Juan) se realiza investigación y desarrollo respecto a la automatización de procesos de molienda de minerales aproximadamente desde el año 2000. Desde hace algunos años se viene desarrollando el Área de Procesamiento de Imágenes.

Actualmente se está trabajando en la caracterización de arenas especiales (calidad, forma, color, tamaños, clasificación del tipo de material, etc.) mediante el procesamiento de imágenes para ser utilizadas en la extracción de petróleo mediante el método de *Fracking*.

### 3. RESULTADOS OBTENIDOS

En este estudio se usará como medida de referencia de la redondez la establecida por Wadell [3]:

$$R_w = \frac{\sum_{i=1}^N r_i / N}{r_{\max\_in}} \quad (1)$$

Donde  $r_i$  es el radio de curvatura de las esquinas, definiéndose las mismas como “aquellas partes del contorno de un área que tiene un radio de curvatura menor o igual que el radio de curvatura del máximo círculo inscripto  $r_{\max\_in}$  en la misma área”.

El cálculo manual de esta fórmula es tedioso, por lo cual se recurre a métodos alternativos como el visual establecido por la norma API 19C y los que se presentarán a continuación basados en visión artificial. Aun así, el cálculo manual a partir de (1) se ha realizado en este estudio en 572 figuras que se han usado como referencia, a fin de poder entrenar redes neuronales que se alimentan con datos alternativos, los cuales se describirán a continuación. Estas figuras cubren todo el rango habitual de mediciones de redondez entre 0.1 y 1, y están combinadas con esfericidad que también cubren todo el rango posible.

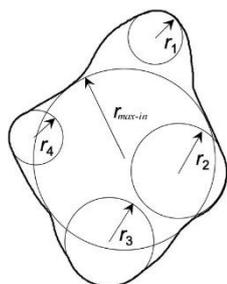


Figura 1: Definición de radios de curvaturas de esquinas y máximo círculo inscripto.

Si bien algunos de los procedimientos que se han usado por visión artificial – y que se describirán a continuación– recurren estrictamente a la expresión (1), ciertas dificultades particulares de los mismos hacen que sea necesario recurrir a medidas alternativas que complementen las mismas a fin de entregar un valor final representativo. Todos estos datos son ingresados a distintas

redes neuronales que entregarán finalmente el valor correcto de  $R_w$ .

Los datos básicos obtenidos por visión artificial, usados para alimentar las redes neuronales son los siguientes:

1) Perímetro de la elipse equivalente  $pEeq$ . Es la elipse que minimiza la diferencia de superficie entre la misma y la partícula en consideración. Es usada en este estudio como una medida de la definición de la imagen de la partícula. Si  $pEeq$  es suficientemente grande, se puede asegurar que el contorno de la partícula contendrá la suficiente cantidad de píxeles como para realizar cálculos por la expresión (1); caso contrario habrá que recurrir a medidas complementarias.

2) Redondez basada en el perímetro  $R_p$ . Está definida como [12]

$$R_p = (pEeq / P)^2 \quad (2)$$

Donde  $P$  es el perímetro en píxeles de la partícula analizada. Si la misma fuera perfectamente elíptica, entonces  $pEeq = P$  y en consecuencia  $R_p = 1$ . En cambio, a medida que la partícula presenta convexidades y concavidades,  $pEeq < P$  y por lo tanto  $R_p < 1$ . Esta es una medida de redondez que no se corresponde con la Wadell  $R_w$  (1), pero es muy consistente para bajas redondeces y por lo tanto útil para alimentar una red neuronal que luego entregará el valor de  $R_w$ .

3) Relación entre el perímetro del máximo círculo inscripto al perímetro de la figura. Definida como

$$P_{mci}2P = 2 \pi r_{\max\_in} / P \quad (3)$$

Esta medida, aunque no definitiva, es complementaria e indicativa de la rugosidad de la partícula, al igual que (2), y por lo tanto útil para complementar la información que entra a las redes neuronales. Mientras más oscilaciones tenga el contorno (menor redondez), mayor será  $P$  y menor será  $P_{mci}2P$ .

4) Esfericidad de ejes  $E_e$

$$E_e = mal / Mal \quad (4)$$

Donde  $a$  y  $b$  son los ejes mayor y menor de la elipse equivalente de la figura considerada. Esta medida también es introducida como información complementaria, debido a que es sabido que las medidas alternativas como (2) sufren alteraciones debidas al nivel de esfericidad.

5) Cálculo de redondez según Wadell (1)  $R_{wz}$  usando el algoritmo de Zheng y Hryciw [15]. Este algoritmo detecta las zonas de convexidad de la partícula por técnicas estrictamente geométricas, básicamente trazando una línea entre distintos puntos del contorno y detectando si dicha línea queda incluida en la partícula o fuera de ella. Luego, un conjunto de puntos convexos cercanos entre sí (Figura 2b) son tomados para encontrar por mínimos cuadrados el círculo que mejor se ajusta a dicho puntos [16].

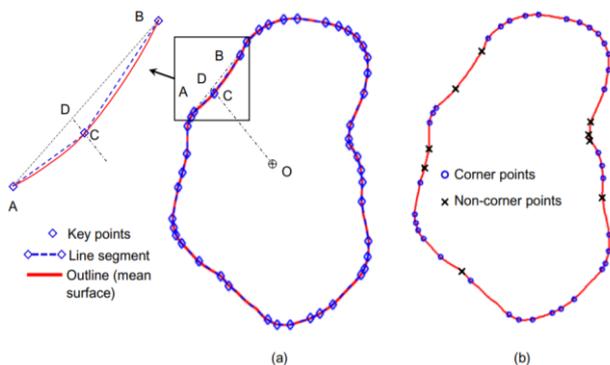


Figura 2: Identificación de esquinas según el método de Zheng y Hryciw.

La desventaja de este método es que la detección de zonas convexas puede fallar si la imagen de la partícula no tiene suficiente definición.

6) Cálculo de redondez según Wadell (1)  $R_{wc}$  detectando las zonas convexas por medio de la descripción polar de la partícula (propuesta de los autores). Véase la Figura (3).

En este caso la detección de las esquinas se realiza mediante el análisis de la derivada segunda de  $\rho(\varphi)$ , y una vez detectados los puntos correspondientes se realiza un ajuste de círculos en una forma semejante al caso anterior. Los resultados son semejantes al algoritmo de Zheng, pero mientras aquel tiene el problema ya descrito en relación con la definición en píxeles de la imagen, este procedimiento tiene el problema de que no se

puede aplicar cuando hay reentrancia del radio polar, es decir cuando hay más de un radio  $\rho$  para un determinado ángulo  $\varphi$ , o sea, cuando  $\rho(\varphi)$  no es biunívoca.

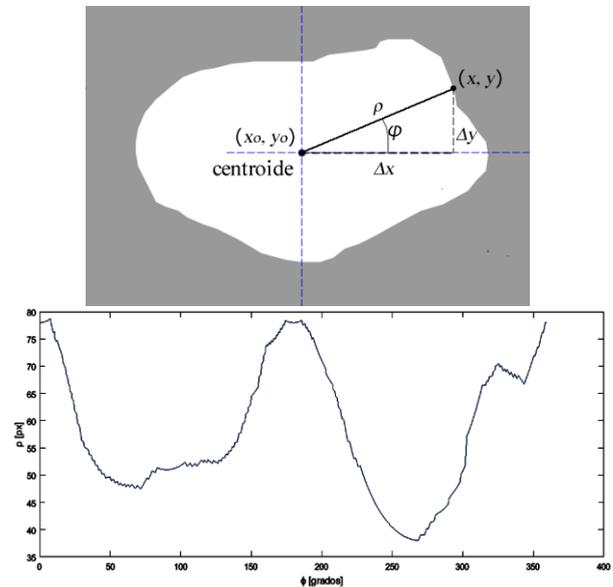


Figura 3: Descripción polar del contorno

Los procedimientos 5) y 6), entonces, aunque en muy pocos casos, pero pueden fallar, y en dichos casos hay que alimentar las redes neuronales con los datos 1) a 4), como se muestra a continuación.

#### Definición de las redes neuronales

A los fines de llegar a un cálculo final, se definen cuatro redes neuronales según la tabla siguiente.

	Net1	Net 2	Net 3	Net 4
Condiciones	Existen $R_{wc}$ y $R_{wz}$	No existe $R_{wc}$	No existe $R_{wz}$	No existe ni $R_{wc}$ ni $R_{wz}$
Entradas	1. $pEq$	1. $pEq$	1. $pEq$	1. $pEq$
	2. $Rp$	2. $Rp$	2. $Rp$	2. $Rp$
	3. $R_{wc}$	3. $R_{wz}$	3. $R_{wc}$	3. $Pmci2P$
	4. $R_{wz}$	4. $Pmci2P$	4. $Pmci2P$	4. $Ee$
	5. $Pmci2P$	5. $Ee$	5. $Ee$	
	6. $Ee$			

Tabla 1: Definición de entradas de las redes neuronales de cálculo

Las cuatro redes neuronales han sido entrenadas utilizando como datos de

entrenamiento las redondeces calculadas manualmente de las 572 figuras de referencia citadas previamente.

Dado que en la gran mayoría de los casos el cálculo de  $R_{wc}$  y  $R_{wz}$  es posible, la red más usada para el cálculo final es Net1.

La correlación obtenida en la medición de las figuras de referencia se muestra en la Figura 4, donde se observa un buen ajuste de las mediciones.

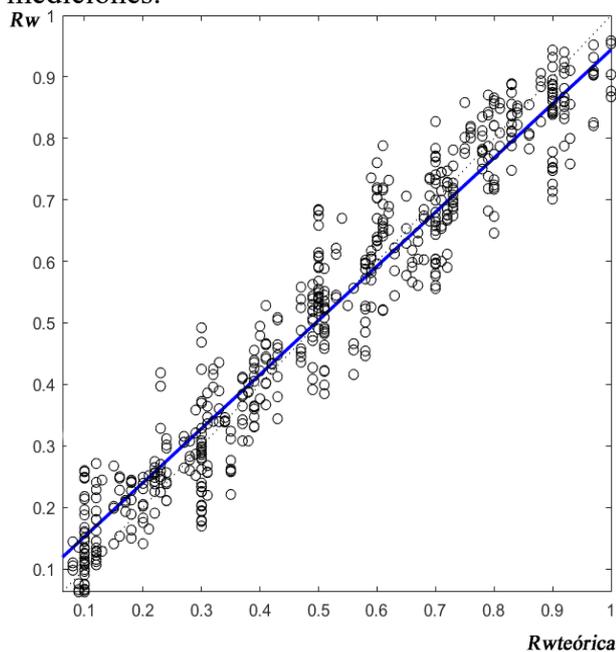


Figura 4: Ajuste de los datos obtenidos a la medida teórica.

El Coeficiente de correlación obtenido es de 0.947, y la recta de ajuste es

$$R_w = 0.88 R_{wteórica} + 0.064 \quad (5)$$

Basados en estos valores, se puede afirmar que el procedimiento es confiable.

Al momento de realizar el análisis de una muestra, el procedimiento por visión artificial permite considerar muchas más partículas (típicamente entre 200 y 500) en lugar de las 20 establecidas por la norma API. Esto le da una validez estadística de gran confiabilidad, y las diferencias de los promedios obtenidos por el procedimiento descrito en este artículo y los teóricos encontrados manualmente oscilan entre el 1% y 5%.

Otro tanto se puede decir de las otras variables geométricas necesarias para definir la calidad de la arena, a saber, la esfericidad y la distribución granulométrica.

Se ha logrado entonces un procedimiento de medición seguro, repetitivo, rápido y que no depende de la subjetividad de un operador.

Si bien es preferible que las imágenes necesarias para alimentar el algoritmo provengan de un microscopio con alto aumento, acompañado de una cámara de alta precisión, del orden de los 5Mpíxeles, los resultados obtenidos con imágenes de poca precisión –un microscopio USB estándar de bajo costo- han dado resultados también con el mismo nivel de error promedio final.

#### 4. FORMACIÓN DE RECURSOS HUMANOS

El grupo de investigación está conformado por Ingenieros Electrónicos, Electromecánicos, en Minas, Metalurgistas y Geólogos, con formación diversa en posgrados, tal como Doctorado en sistemas de control, Maestría en informática, Especialización en gestión y vinculación tecnológica, etc.

Actualmente, dos integrantes del equipo de trabajo se encuentran desarrollando su Tesis de Doctorado en Ingeniería de Procesamiento de Minerales, siendo su director de Tesis otro de los integrantes del grupo de investigación.

#### 5. BIBLIOGRAFIA

- [1] ANSI/API (2008). Recommended practice 19C -First Edition, - Part 2: Measurement of properties of proppants used in hydraulic fracturing and gravelpacking operations.
- [2] Krumbein, W.C.; Sloss, L.L. (1963). Stratigraphy and Sedimentation; 2nd ed. W.H. Freeman: San Francisco.
- [3] Wadell, H. (1932). Volume, Shape, and Roundness of Rock Particles. Jour. Geol., XL (5), 443–451.
- [4] Wadell, H. (1933). Sphericity and Roundness of Rock Particles. Jour. Geol., XLI(3), 310–331.

- [5] Wadell, H. (1935). Volume, Shape and Roundness of Quartz Particles. *Jour. Geol.* XLIII(3), 258–280.
- [6] Rodriguez, J.M. (2013). Importance of the Particle Shape on Mechanical Properties of Soil Materials. *Licenciate Thesis*, Luleå University of Technology, Luleå.
- [7] Andersson, T. (2010). Estimating Particle Size Distributions Based on Machine Vision. *Doctoral Thesis*, Luleå University of Technology, Luleå.
- [8] Mora, C.K. (2000) Sphericity, Shape Factor, and Convexity Measurement of Coarse Aggregate for Concrete Using Digital Image Processing. *Cement and Concrete Research* 30(3), 351–358.
- [9] Roussillon, T.; Piégay, H.; Sivignon, I.; Tougne, L.; Lavigne, F. (2009). Automatic Computation of Pebble Roundness Using Digital Imagery and Discrete Geometry 35, 1992–2000, doi:10.1016/j.cageo.2009.01.013.
- [10] Drevin, G.R. (2007). Computational Methods for the Determination of Roundness of Sedimentary Particles. *Math Geol* 38, 871–890, doi:10.1007/s11004-006-9051-y.
- [11] Altuhafi, F.; O’Sullivan, C.; Cavarretta, I. (2013). Analysis of an Image-Based Method to Quantify the Size and Shape of Sand Particles. *J. Geotech. Geoenviron. Eng.* 139, 1290–1307, doi:10.1061/(ASCE)GT.1943-5606.0000855.
- [12] Charalambous, C. (2015). On the Evolution of Particle Fragmentation With Applications to Planetary Surfaces. *Doctoral Thesis*, Imperial College London.
- [13] Rodriguez, J.; Edeskär, T.; Knutsson, S. (2013). Particle Shape Quantities and Measurement Techniques - A Review. *Electronic Journal of Geotechnical Engineering* 18(A), 169–198.
- [14] Sun, T.H. (2009). Applying Particle Swarm Optimization Algorithm to Roundness Measurement. *Expert Systems with Applications* 36, 3428–3438, doi:10.1016/j.eswa.2008.02.072.
- [15] Zheng, J.; Hryciw, R. (2015). Traditional Soil Particle Sphericity, Roundness and Surface Roughness by Computational Geometry. *Géotechnique* 65, 494–506, doi:10.1680/geot.14.P.192.
- [16] Gander, W.; Golub, G.; Strebler, R. (1994). Least-Squares Fitting of Circles and Ellipses. *BIT* 34, 558–578, doi:10.1007/BF01934268.
- [17] Chuk, O.D.; Rodriguez Medina, C.G.; Luna, A. (2021). Roundness Calculus of Frack-ing Sands Using Artificial Vision and Fourier Transform. *Anales de XV Jornadas de Tratamiento de Minerales*; UNSJ, San Juan, Argentina.