

CLASIFICACIÓN DE PARTÍCULAS DE ARENA A TRAVÉS DE REDES NEURONALES CONVOLUCIONALES

Mg. Ing. Carlos Gustavo Rodriguez Medina ¹, Dr. Ing. Oscar Daniel Chuk ²,
Lic. Adriana Luna, Ing. Regina Bertero.

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 ¹, int. 389 ^{1,2})

grodriguez@unsj.edu.ar ¹, dchuk@unsj.edu.ar ²

RESUMEN

Se presenta una alternativa para clasificar partículas de arenas, en cuanto a la característica de redondez, utilizando redes neuronales convolucionales. Se ha seleccionado este tipo de redes neuronales, por la atractiva posibilidad de poder operar directamente sobre las imágenes digitales de partículas de arena, sin la necesidad de tener que extraer previamente características o medidas alternativas de las imágenes. Esta propuesta resulta ser una opción diferente a la utilización de redes neuronales que no aplican convolución, y también a técnicas de visión artificial (que emplean cálculos, métodos y medidas alternativas para estimar valores de redondez).

La necesidad de poder clasificar las partículas en cuanto a su redondez, radica en que estas arenas se utilizan en procesos de fracturación hidráulica para la extracción de hidrocarburos de manera no convencional. Estos yacimientos no convencionales requieren 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.

El método indicado por la norma (tradicional no automatizado) para la medición de redondez tiene una alta dependencia del criterio del observador o laboratorista, que analiza una muestra mediante un microscopio eligiendo un número muy reducido de partículas al azar, y comparándolas visualmente con formas gráficas establecidas en una cartilla.

Palabras clave: Redes neuronales convolucionales, Partículas de arena, Redondez, Fracturación hidráulica.

CONTEXTO

Este trabajo presenta de manera resumida los resultados del Proyecto de Investigación Científica (PIC – UNSJ) “*Clasificación de partículas de arena de fracturación mediante redes neuronales convolucionales*”, ejecutado durante el periodo 2020 – 2022, financiado por la Universidad Nacional de San Juan.

Dicho proyecto se inscribe 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

En la industria de extracción de petróleo de manera no convencional, y con la finalidad de garantizar la capacidad de las arenas con destino a los procesos de fracturación hidráulica (*Fracking*), para actuar como apuntalantes o propantes, se reconocen como base las normas de referencia del *American Petroleum Institute (API) 19C* [1, 2]. Esta norma recomienda una serie de ensayos a realizar sobre las arenas con el fin de conocer la calidad del material a utilizarse en el proceso. Entre los ensayos a aplicarse se encuentran los de redondez y esfericidad, entre otros.

Tales ensayos padecen de una fuerte dependencia del criterio del observador, dado que el procedimiento se aplica mediante la utilización de un microscopio y las mediciones de redondez y esfericidad se realizan por comparación respecto a tablas que contienen una serie de formas provistas por la norma, mediante unas cartas gráficas conocidas como tablas o cartillas de *Krumbein y Sloss* [3]. Esto deriva en resultados sustancialmente disímiles que invalidan el procedimiento, aunque es el que se sigue usando por norma.

El uso de técnicas de Visión Artificial se presenta como la alternativa tecnológica que puede permitir obtener medidas objetivas no dependientes del criterio de un operador [1]. En este sentido el grupo de investigación ha elaborado varios algoritmos con diversos objetivos aplicados al procesamiento digital de partículas que van desde la segmentación hasta el cálculo de medidas geométricas, tales como el de esfericidad, redondez, tamaño, distribución granulométrica, etc. [1, 4]

Las partículas pueden presentar entre ellas distintas variaciones, pudiendo ser algunas más redondeadas, o con más puntas, más o menos achatadas, más o menos alargadas, de diferentes tamaños, etc.

Dado que esta situación que se presenta, es un problema relacionado con la forma de las partículas, se sabe que existen herramientas de la inteligencia artificial orientadas a resolver problemas de reconocimiento de

formas, patrones y su clasificación; éstas son las redes neuronales artificiales [4, 9, 10].

Además, hay un tipo particular de redes neuronales que permiten operar directamente sobre un conjunto de imágenes, sin necesidad de tener que realizar ningún pre-procesado para la extracción de las características de interés, estas son las redes neuronales convolucionales [5, 8].

Las redes neuronales convolucionales son especialmente útiles para localizar patrones en imágenes con el objetivo de reconocer objetos, formas, etc. Se puede decir que aprenden directamente a partir de los datos de las imágenes [4].

Al igual que otras redes neuronales, una red neuronal convolucional se compone de una capa de entrada, una capa de salida y muchas capas ocultas intermedias. A su vez, las capas intermedias ocultas se organizan de forma alternada con capas convolucionales y de pooling, finalizando con una serie de capas de neuronas completamente conectadas (*Full connected*) [5].

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 *Fraking*.

3. RESULTADOS OBTENIDOS

Dado a que las redes neuronales requieren de un proceso de entrenamiento previo a su utilización, se debe contar con un conjunto de

datos lo más representativo posible de las imágenes con las cuales se necesita trabajar; para este caso se trata de imágenes de partículas de arena. A la vez, este conjunto de imágenes se divide en un conjunto de entrenamiento y otro de validación para poder comprobar el desempeño de la red entrenada. En la figura 1 se muestra un ejemplo de imágenes en blanco y negro (del tipo binarias) de partículas de arena. Para este caso, cuando se utilizan imágenes capturadas mediante un microscopio, las mismas deben convertirse de RGB a binario, para luego ser ingresadas a la red neuronal.



Figura 1. Imágenes en blanco y negro de partículas de arena.

Para poder entrenar una red neuronal y que luego la misma logre determinado nivel de acierto en la predicción de la variable de interés, y con mayor razón si se trata de una red del tipo convolucional, se necesitan grandes cantidades de imágenes para llevar a cabo dicho proceso adecuadamente. Por tal motivo, y debido a que no se disponía de un banco de imágenes de partículas de arena con tal característica, es que se trabajó en la elaboración de un banco de imágenes de partículas realizadas mediante la utilización de funciones matemáticas para graficar elementos geométricos básicos y la aplicación de procesamiento digital computacional [6]. Ha tales imágenes se las ha denominado como partículas “artificiales” de arena [7], la figura 1 corresponde a éstas.

Además, se debe tener en cuenta que para este tipo de redes se debe contar con un grupo de

etiquetas o valores de redondeces que se correspondan con cada imagen del conjunto de datos. Con estos pares de datos (imágenes y etiquetas) es con lo que se nutre la red (entradas) para llevar a cabo el aprendizaje.

El conjunto inicial de imágenes (artificiales) para entrenamiento y validación, obtenido en un primer momento, era aproximadamente de 150 imágenes de partículas de arena por cada etiqueta (unas 600 en total), el cual resultaba ser un número importante comparado con el que se contaba si solo se disponía la tabla de *Krumbein y Sloss* [3], obsérvese en la figura 2. Pero ya se mencionó que para el entrenamiento de una red neuronal convolucional se requieran grandes cantidades de imágenes, por lo cual seguía siendo insuficiente dicha cantidad.

Por lo tanto, aplicando procesamiento digital de imágenes y mediante funciones de rotación y también de espejado se obtuvieron más de 50.000 imágenes. De esta manera, el conjunto que se obtuvo fue el adecuado para poder comenzar a obtener algunos resultados de interés una vez llevado a cabo el entrenamiento.

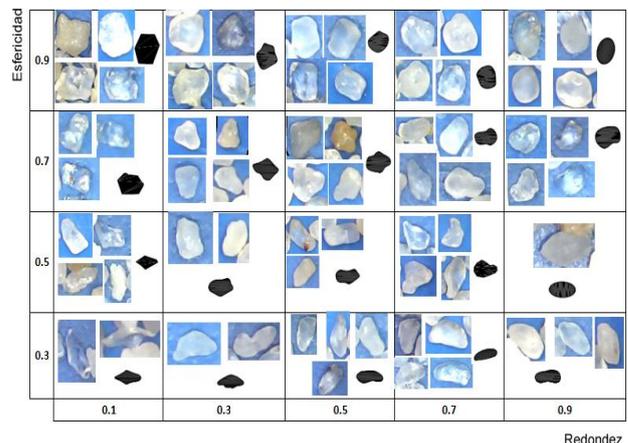


Figura 2. Cartilla de Krumbein y Sloss.

De acuerdo a las tablas de *Krumbein y Sloss* [3], la redondez puede tomar valores entre 0.1 y 0.9, figura 2. Debido a los importantes recursos de hardware que requiere una red neuronal convolucional para llevar a cabo el proceso de entrenamiento, y más cuando se necesita disponer de varias salidas, es que en este trabajo se acota a entrenar la red para clasificar las partículas con redondeces entre

0.1 y 0.4. El tiempo insumido en el entrenamiento lógicamente también es mayor cuando no se cuenta con el procesamiento adicional de una placa grafica con GPU dedicada.

Para el entrenamiento y validación de la red, se ha utilizado un equipo informático con procesador Intel i5 de 4 núcleos, 8GB de RAM y no se dispone de GPU dedicada.

Se ha utilizado el software matemático Matlab para la implementación de los algoritmos de las redes neuronales convolucionales, para el proceso de entrenamiento y pruebas, como así también para la generación de las partículas artificiales de arena, procesamiento de imágenes y armado de los distintos conjuntos de entrenamiento y validación.

Red neuronal

La red neuronal convolucional desarrollada se conforma de 5 capas de Convolución y Pooling alternadas, para luego unirse a una capa Completamente conectada (*Full-connected*). La salida se compone de los posibles 4 valores de redondeces antes indicados (0.1, 0.2, 0.3 y 0.4).

En la tabla I se resume el conjunto de imágenes de partículas de arena elaborado para estas pruebas, en la que se presentan las etiquetas que referencian a los valores de redondez y a la cantidad de imágenes que contiene cada una.

Etiqueta (redondez)	Cant. Imágenes
1 (0.1)	13.320
2 (0.2)	14.400
3 (0.3)	14.580
4 (0.4)	14.760

Tabla I. Conjunto de datos.

El conjunto de entrenamiento utilizado para la prueba que se presenta es de 8.000 imágenes para cada valor de redondez, por lo que por ej. para el caso de la primera etiqueta de redondez se tiene aproximadamente un 60% del conjunto de datos subdividido para el proceso de entrenamiento, y el resto para validar dicho entrenamiento.

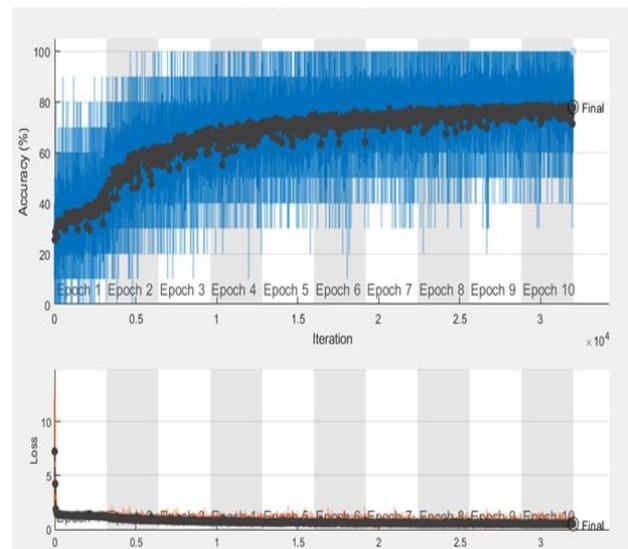


Figura 3. Resultado de entrenamiento de la red neuronal convolucional.

El entrenamiento realizado para este ejemplo ha insumido un tiempo de 908 min (poco más de 15hs). El mismo logró una precisión del 77.98%. En la figura 3 se presenta la pantalla de resultado arrojada por Matlab. También se aprecia que la red neuronal a medida que transcurre el tiempo de entrenamiento va aumentando su precisión, hasta casi alcanzar prácticamente el 80%.

	1	2	3	4
1	4749	479	65	27
2	870	4636	758	136
3	80	503	4356	1641
4	7	32	298	6423
	1	2	3	4

Figura 4. Matriz de Confusión de la prueba realizada a la red neuronal convolucional.

En la figura 4 se presenta el resultado de testear el desempeño de la red neuronal, a través de la Matriz de Confusión.

De acuerdo a la Tabla I, y teniéndose en cuenta que para el entrenamiento se utilizaron 8.000 imágenes de partículas de arena de cada

etiqueta, entonces en la Tabla II se indican las cantidades de imágenes utilizadas para la prueba realizada a la red neuronal y así poder comparar y analizar junto a la Matriz de Confusión.

Etiqueta (redondez)	Cant. imágenes
1 (0.1)	5.320
2 (0.2)	6.400
3 (0.3)	6.580
4 (0.4)	6.760

Tabla II. Datos utilizados para la prueba.

De la figura 4, se aprecia que cuando se ingresan como entradas a la red neuronal imágenes de partículas de arena con una redondez de 0.1 (etiqueta 1), la red clasificó adecuadamente (eje indicado como *predicted class*) con redondez 0.1 (etiqueta 1) a 4749 imágenes (89.2%). También se puede observar que 479 imágenes (9%) fueron identificadas con una redondez de 0.2 (etiqueta 2) erróneamente, Así también, alejándose un poco más del resultado correcto, se observa que a 65 imágenes (1.2%) la red las identificó con la etiqueta 3 erróneamente (redondez 0.3). Finalmente, solo 27 imágenes (0.5%) identificó erróneamente con una redondez de 0.4 (etiqueta 4). Obsérvese que los elementos de la diagonal principal de dicha matriz se encuentran coloreados en azul, indicando las cantidades de aciertos obtenidos por la red neuronal. Por lo tanto, los elementos fuera de la diagonal corresponden a valores erróneos (predicciones incorrectas de la red). De esta manera se puede recorrer toda la matriz para analizar el desempeño de la red neuronal, y apreciar la cantidad de imágenes con determinado valor de redondez ingresadas como entradas, y observar los valores predichos por la red y obtenidos a la salida.

Si se calcula el porcentaje promedio de errores cometidos por la red (analizando la matriz de confusión completamente), para este caso se tiene que es del 19,27%, el cual resulta ser razonable teniendo en cuenta el porcentaje de aciertos (*Accuracy*) obtenido durante el entrenamiento, indicado en párrafos anteriores.

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, uno de los integrantes del equipo de trabajo se encuentra 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] Rodriguez Medina, C.G.; Chuk, O.D.; Bertero R.; Luna, A.; Núñez, E.; Trigo, P. Visión artificial aplicada a la determinación de propiedades geométricas de arenas de fracturación para el análisis de calidad. Informe de Final de Proyecto PIC CICITCA. Universidad Nacional de San Juan. 2019.
- [2] American Petroleum Institute API 19C, Second Edition: Measurement of Properties of Proppants Used in Hydraulic Fracturing and Gravel-Packing Operations; API Publishing Services: Washington, D.C., 2008
- [3] Krumbein, W.C.; Sloss, L.L. Stratigraphy and Sedimentation; 2nd ed.; W.H. Freeman: San Francisco, 1963;
- [4] Rodriguez Medina, C. G.; Chuk, O.D.; Bertero, R. Luna, A.; Núñez, E.. Redes neuronales para la clasificación de partículas de arena. WICC 2021. XXIII Workshop de Investigadores en Ciencias de la Computación. Universidad Nacional de Chilecito. Pág. 149 – 154. 2021. ISBN 978-987-24611-3-3.
- [5] Mathworks. Redes neuronales convolucionales. 1994-2022. <https://la.mathworks.com/discovery/convolucional-neural-network-matlab.html>
- [6] Charoenpong, T.; Chamnongthai, K.; Kamhom, P.; Krairiksh, M. Volume Measurement of Mango by Using 2D Ellipse Model. In Proceedings of the 2004 IEEE

- International Conference on Industrial Technology, 2004. IEEE ICIT '04.; December 2004; Vol. 3, pp. 1438-1441.
- [7] Rodriguez Medina, C.G.; Chuk, O.D.; Bertero, R. Luna, A.; Núñez, E. Generación gráfica de partículas artificiales de arena para su utilización en redes neuronales. WICC 2020. XXII Workshop de Investigadores en Ciencias de la Computación. Universidad Nacional de la Patagonia Austral. Pág. 307 – 312. 2020. ISBN 978-987-3714-82-5.
- [8] Liang, Z.; Nie, Z.; An, A.; Gong, J.; Wang, X. A Particle Shape Extraction and Evaluation Method Using a Deep Convolutional Neural Network and Digital Image Processing. *Powder Technology* Pag. 156-170. 2019. doi:10.1016/j.powtec.2019.05.025.
- [9] Jain, A. K. Statistical Pattern Recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol 22, Nro. 1. 2000.
- [10] Haykin S. *Neural Networks - A comprehensive foundation*, IEEE Press - Macmillan College Publishing Company, Inc. 1994.
- [11] Hryciw, R.D.; Zheng, J.; Shetler, K. Particle Roundness and Sphericity from Images of Assemblies by Chart Estimates and Computer Methods. *Journal of Geotechnical and Environmental Engineering* 2016, 142, 04016038, doi:10.1061/(ASCE)GT.1943-5606.0001485.
- [12] Hernandez, E.M.; Chavez, G.M.; Hernandez, J.V. Roundness Estimation of Sedimentary Rocks Using Elliptic Fourier and Deep Neural Networks. In Proceedings of the 2020 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC); IEEE: Ixtapa, Mexico, November 4 2020; pp. 1–5.
- [13] Wadell, H. Volume, Shape, and Roundness of Rock Particles. *Jour. Geol.* 1932, XL, N°5, 443–451.