

GENERACION GRAFICA DE PARTICULAS ARTIFICIALES DE ARENA PARA SU UTILIZACIÓN EN REDES NEURONALES

Mg. Ing. Carlos Gustavo Rodriguez Medina ¹, Dr. Ing. Oscar Daniel Chuk ²,
Ing. Regina Bertero, Lic. Adriana Luna, Ing. Enrique Núñez. Sr. Darío Quinteros

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

El presente trabajo expone una alternativa para generar un conjunto de datos, correspondiente a imágenes de partículas de arenas, con el propósito de ser utilizadas en el entrenamiento de una Red Neuronal Convolutiva para la clasificación teniendo en cuenta sus características de redondez y esfericidad. La necesidad de medir tales características en estas arenas, se debe a que permite estimar la calidad para su utilización en procesos de fracturación hidráulica (*fracking*) para la extracción de petróleo de manera no convencional.

La utilización de Redes Neuronales posibilita identificar y clasificar elementos de interés, en base a un entrenamiento previo, para ello se debe contar con un conjunto de datos de entrenamiento con un elevado número de elementos (entre 1.000 y 10.000 muestras aproximadamente), para obtener resultados aceptables. Por lo cual esto requiere contar con un conjunto de imágenes de arenas, que sean representativas de todo el espectro posible a identificar, y rotuladas con sus correspondientes valores de redondez y esfericidad.

Se propone una alternativa para el armado de tal conjunto, la que consiste en graficar partículas de arenas, mediante métodos geométricos y matemáticos, por medio de un software matemático especializado, calculando simultáneamente los valores de

redondez y esfericidad, lográndose así el armado del conjunto de datos requerido compuesto de imágenes artificiales de partículas de arena, etiquetadas con las características antes mencionadas. Esto se obtiene mediante un algoritmo computacional desarrollado específicamente y que permite el graficado y medición de manera automatizada, prefijando ciertos parámetros.

Palabras clave: Partículas artificiales de arena, Procesamiento de imágenes, Redes Neuronales, Datos de entrenamiento, Fracturación hidráulica.

CONTEXTO

El tema del trabajo propuesto surge como una alternativa de solución a una problemática surgida durante la ejecución del proyecto de Investigación y Creación (PIC – CICITCA) titulado “*Visión artificial aplicada a la determinación de propiedades geométricas de arenas de fracturación para el análisis de calidad*”, desarrollado durante 2018 y 2019. Dicho trabajo de elaborar gráficamente una partícula artificial de arena para poder conformar un conjunto de datos para el uso en Redes Neuronales se continua en la propuesta de Proyecto de Investigación y Creación presentada para el periodo 2020 y 2021 titulado “*Clasificación de partículas de arena*”

de fracturación mediante redes neuronales convolucionales”.

Los mencionados proyectos se inscriben dentro de la línea de investigación que lleva adelante el grupo de trabajo en la temática de Visión Artificial e Inteligencia Artificial orientado al control automático de minerales, que se viene desarrollando hace varios años en el Instituto de Investigaciones Mineras de la Facultad de Ingeniería de la UNSJ.

1. INTRODUCCIÓN

Con la finalidad de garantizar la capacidad de las arenas con destino a los procesos de *Fracking* para actuar como apuntalantes o propantes, se reconocen como base las normas de referencia del *American Petroleum Institute* (API) [1]. Esta norma recomienda una serie de ensayos a realizar sobre las arenas con el fin de conocer la calidad del material a utilizarse en la fracturación hidráulica. Entre los ensayos a realizarse se encuentran los de redondez y esfericidad de las partículas de arena.

Tales ensayos padecen de una fuerte dependencia del criterio del observador, dado que el procedimiento se realiza mediante la utilización de un microscopio y las mediciones de esfericidad y redondez se realizan por comparación respecto a tablas que contienen una serie de formas provistas por la norma (cartillas de *Krumbein y Sloss* – figura 1). 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]

Cada partícula de arena puede presentar diversas variaciones unas a otras, 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 conocidas como Redes Neuronales Artificiales [2].

Las Redes Neuronales Artificiales (RNA) son modelos de procesamiento de información, inspirados por la forma en que el cerebro procesa información. Aunque son una simplificación de las redes neuronales biológicas, las RNA son aptas para resolver problemas que la gente puede resolver, pero las computadoras no pueden, o los algoritmos resultan muy complicados. [3]

Las neuronas biológicas son componentes relativamente simples del cerebro, pero cuando millares de ellas se conectan en forma conjunta se hacen muy poderosas (conforman una Red), esto justifica la alta capacidad de cómputo del cerebro. Una red neuronal artificial está constituida por muchos elementos simples de procesamiento, organizados en niveles y muy interconectados. [4]

Aprendizaje de la red neuronal artificial:

El conocimiento es adquirido por la red a través de un proceso que se denomina aprendizaje; dicho conocimiento se almacena mediante la modificación de la fuerza o peso sináptico de las distintas uniones entre elementos de procesamiento. [5].

Todo conocimiento de una red neuronal se encuentra distribuido en los pesos sinápticos de las neuronas. Una red neuronal artificial aprende a través de un proceso de ajuste de sus pesos sinápticos. El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos sinápticos en respuesta a una entrada, para proporcionar la salida adecuada. [3]

Los cambios que se producen durante el proceso de aprendizaje implican la destrucción, modificación y creación de conexiones entre las neuronas. La creación de una nueva conexión consiste en que el peso de la misma pasa a tener un valor distinto de cero, una conexión se destruye cuando su peso pasa a ser cero.

Datos de entrenamiento y problemática presentada:

Dado que para trabajar con una red neuronal se debe contar con un conjunto o *set* de elementos (específicamente imágenes de partículas de arena en este contexto), estos conjuntos deben contener un número elevado de elementos o imágenes, debido a que dicho conjunto se debe dividir en dos subconjuntos, uno de entrenamiento (entre un 60% y un 70% del total de las imágenes), y otro subconjunto para el testeo o evaluación del aprendizaje alcanzado por la red neuronal.

Las redes neuronales aumentan su capacidad de generalizar, a medida que el conjunto de entrenamiento es mayor. Si bien, se podría entrenar con un conjunto reducido (en términos relativos) de imágenes, el desempeño de la red aumenta cuanto mayor sea la cantidad de imágenes de entrenamiento, y con mayor razón cuando el tipo de red neuronal a utilizar es del tipo convolucional (tal como se pretende desarrollar en el proyecto de investigación 2020 – 2021).

Una alternativa (ideal) sería el disponer de un banco de imágenes de partículas de arenas ya clasificadas, etiquetadas o rotuladas con los correspondientes valores de esfericidad y redondez. Esta opción es difícil, a pesar de que en el Instituto de Investigaciones Mineras se realizan este tipo de servicios, pero debido a que dicho trabajo se lleva a cabo de manera manual mediante microscopio e inspección visual humana, donde el laboratorista clasifica los granos de arena por comparación mediante las cartillas de *Krumbein y Sloss* (figura 1), lamentablemente no se dispone de estos resultados digitalizados de manera sistematizada. Ni de las partículas de arena y tampoco de la clasificación realizada.

Tal como se dijo en párrafos anteriores, la norma que se aplica para la determinación de los parámetros de calidad de las partículas de arena para *Fracking*, utiliza las cartillas de *Krumbein y Sloss*, para clasificarlas en cuanto a redondez y esfericidad, tal como se expone en la figura 1. Dicha tabla posee solamente 20 elementos gráficos de acuerdo a distintos valores de redondez y esfericidad, los que resultan extremadamente insuficientes si se

quisieran utilizar estos elementos imágenes de partículas de arena para llevar a cabo el entrenamiento de la red neuronal.

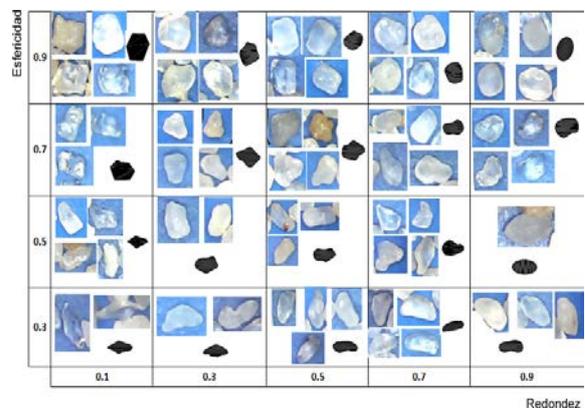


Figura 1. Cartilla de esfericidad y redondez de *Krumbein y Sloss*

Entonces, si no se puede utilizar la tabla de la figura 1 para el proceso de entrenar la red neuronal, y tampoco se cuenta con trabajos de clasificación anteriores, se debe buscar una alternativa para generar un conjunto de datos de entrenamiento y de testeo con una cantidad de elementos lo suficientemente grande para lograr que la red pueda clasificar las partículas de arena adecuadamente

Propuesta:

Con el objeto de poder desarrollar un conjunto de datos lo suficientemente grande, de acuerdo a las necesidades de entrenamiento de la red neuronal (para la clasificación de partículas de arena), se propone generar de manera gráfica, mediante el software matemático Matlab [6], partículas de arena que no son imágenes tomadas mediante un microscopio a granos de arena reales, sino que las mismas son elaboradas mediante funciones matemáticas (elementos geométricos básicos tales como elipses y círculos), pudiéndose así hacer referencia como un conjunto de elementos de partículas “artificiales” de arena.

Tales imágenes generadas, tienen la particularidad que como están compuestas por formas básicas de elipses y círculos, entonces se puede aplicar con cierta facilidad la ecuación desarrollada por *Wadell* (1932) para

el cálculo de la redondez, tal como se expone en la Ecuación 1. A la vez resulta de importancia aclarar que la cartilla de *Krumbein y Sloss (1963)* se basa en la aplicación de la ecuación de *Wadell*.

$$R = \frac{\sum_{i=1}^N r_i}{r_{\max-in}} \quad (\text{Ecuación 1.})$$

Donde:

N: Cantidad de círculos inscriptos.

ri: Radios de los círculos.

r max-in: Radio del máximo círculo inscripto

Por lo tanto, a cada partícula generada gráficamente como una partícula artificial se le calcula la redondez mediante la ecuación 1, utilizando *Wadell*, y la correspondiente para el cálculo de esfericidad, por lo que en definitiva se estaría aplicando la referida norma API para la determinación de estas características, utilizando técnicas de inteligencia artificial (procesamiento de imágenes, etc.)

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 hace casi dos décadas. 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*.

De manera complementaria, en búsqueda de dar solución al tema de clasificación de partículas, se ha incursionado en la temática de redes neuronales.

Otra de las líneas de investigación y desarrollo del grupo de trabajo, está orientado

al de optimización. Concretamente, se está trabajando en la optimización multiobjetivo, del tipo predictivo, para la explotación de minas.

3. RESULTADOS OBTENIDOS Y ESPERADOS

Se ha elaborado un algoritmo que posibilita la realización grafica de la partícula artificial de arena. Dicho algoritmo se presenta en la figura 2.

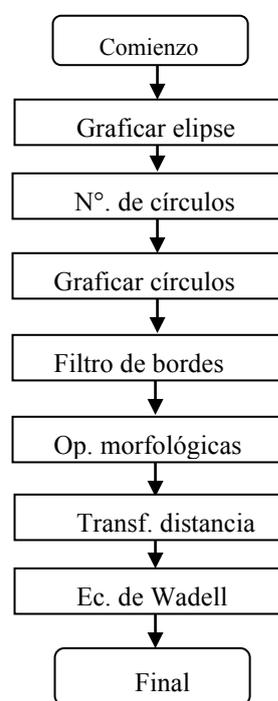


Figura 2. Algoritmo para graficar partículas artificiales de arena.

Sobre una imagen con fondo de color negro se comienza graficando una elipse, determinando las coordenadas y los ejes de la misma. Luego se determina la cantidad de círculos a emplear, relacionado a la cantidad de picos o esquinas de la partícula a generar. En la medida que más círculos o picos se le agreguen a la elipse graficada previamente, menos redondeada será la partícula artificial resultante. Esto se puede apreciar en la figura 3-A. El paso siguiente es aplicar un filtro de bordes, de *Canny* específicamente [7], para poder trabajar solamente con el contorno resultante, esto se observa en la figura 3-B.




Figura 3. Resultados de aplicar el algoritmo para graficar partículas artificiales de arena.

En el diagrama de bloques del algoritmo de la figura 2, se indica que el paso que sigue es el de utilizar operaciones morfológicas, esto se hace con el objeto de lograr un suavizado de la partícula obtenida, ya que hasta esa instancia es muy notoria la presencia de los círculos sobre la elipse. Obsérvese el resultado de aplicar la operación de dilatación y luego la de erosión en la figura 3-C y 3-D, respectivamente.

Como paso siguiente del algoritmo, se realiza el cálculo de la transformada de distancia de la partícula obtenida en la figura 3-D. Esto genera el resultado de la figura 3-E.

Finalmente se calcula la redondez mediante la Ecuación 1 de *Wadell*, utilizando los radios de los círculos inscritos en las esquinas de la partícula artificial, y tomando el valor de la transformada de distancia como el valor del radio del máximo círculo inscrito en la partícula. Se calcula también la esfericidad.

Como resultado preliminar, los cálculos obtenidos mediante la aplicación de la fórmula de *Wadell*, utilizando el algoritmo elaborado (figura 2), es coincidente con el que se obtiene de aplicar las cartillas de *Krumbein y Sloss (figura 1)* para la obtención de los valores de redondez y esfericidad (de acuerdo a las normas API, universalmente utilizada y explicado en el apartado 1).

Tal como antes se mencionó, estos representan resultados preliminares pero prometedores, dado que se logra coincidencia en los resultados obtenidos de clasificar una partícula mediante la Norma API (tabla 1) comparados con la generación gráfica y cálculo realizado mediante la ecuación 1.

Durante el periodo de investigación 2020 - 2021 se trabajará en la optimización del algoritmo y automatización sobre ciertos aspectos.

4. FORMACIÓN DE RECURSOS HUMANOS

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

Actualmente, una de las integrantes del equipo de trabajo, se encuentra desarrollando su Tesis de Doctorado en Ingeniería en procesamiento de minerales, siendo su director de Tesis también otro de los integrantes del grupo de investigación.

Además, como inicio en la carrera de investigador, otra de las actuales integrantes, comenzó hace cuatro años participando de un proyecto PROJOVI (Proyecto de Jóvenes Investigadores), cuya finalidad es la de

permitir que docentes, becarios, y alumnos de la Universidad, menores de 40 años, con o sin experiencia en investigación lleven a cabo dicha actividad. También participó de un proyecto PIC (Proyecto de Investigación y Creación) en el periodo 2018 – 2019.

Además, un alumno avanzado de la carrera de grado de Ingeniería en Electrónica, comienza a participar de un nuevo proyecto PIC a ejecutarse en el periodo 2020 – 2021, llevando a cabo su tesina de fin de carrera.

5. BIBLIOGRAFIA

[1] Rodriguez Medina, C. G.; Chuk, O. D.; Bertero R.; Luna, A.; Núñez, E.; Trigo, P. 2019. Visión artificial aplicada a la determinación de propiedades geométricas de arenas de fracturación para el análisis de calidad. Universidad Nacional de San Juan. Informe de Final de Proyecto PIC.

[2] Jain, A. K. 2000. Statistical Pattern Recognition: a review. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol 22, Nro. 1.

[3] Castro G., J. F. 2006. Fundamentos para la implementación de red neuronal perceptron multicapa mediante software. Tesis de grado. Facultad de Ingeniería, Universidad de San Carlos de Guatemala.

[4] Haykin S. 1994. Neural Networks - A comprehensive foundation, IEEE Press - Macmillan College Publishing Company, Inc.

[5] Long, L. 1990. Introducción a las computadoras y al procesamiento de información. 2ª. Edición; México: Editorial Prentice All Hispanoamericana.

[6] Mathworks. (1994-2019). Image Processing Toolbox.

https://es.mathworks.com/products/image.html?s_tid=srchtitle.

[7] Rodriguez Medina, C. G. y Navas, G. S. 2014. Aplicación del filtro de Canny en la esteganografía digital. XVI Workshop de Investigadores en Ciencias de la Computación - WICC 2014 Ushuaia. RedUNCI. p 806 - 811. ISBN 978-950-34-1084-4.