

REDES NEURONALES PARA LA CLASIFICACIÓN DE PARTÍCULAS DE ARENA

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 Martín 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 trata respecto a la utilización de redes neuronales para el reconocimiento de formas y patrones de imágenes digitales de partículas de arena, con destino al uso en procesos de fracturación hidráulica en explotación de hidrocarburos de manera no convencional (*Fracking*).

Si bien, la mayor parte de las redes neuronales permiten el reconocimiento de patrones y clasificación de objetos, hay un tipo particular de redes que en la actualidad han permitido un salto importante en el procesamiento de información e imágenes, y son las redes neuronales convolucionales. Estas permiten la extracción de características directamente desde las propias imágenes sin la necesidad de un trabajo de pre-procesado.

Es decir, para este caso, se usan como entradas a la red neuronal las imágenes digitales de partículas o granos arena, y no un conjunto de características extraídas de manera previa por parte del diseñador de la red neuronal. En cuanto a la clasificación de las partículas de arena, en este trabajo se refiere en poder determinar a través de la red neuronal convolucional características de Redondez y Esfericidad específicamente.

También se presenta una alternativa para generar el conjunto de datos para el entrenamiento y validación de la red neuronal,

mediante la elaboración de un algoritmo de procesamiento de imágenes que permite la generación artificial (gráfica) de partículas de arena, dado que no siempre se puede disponer de un banco de imágenes adecuado.

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

CONTEXTO

La temática desarrollada representa parte de los avances y resultados del proyecto de Investigación y Creación (PIC – CICITCA) “*Clasificación de partículas de arena de fracturación mediante redes neuronales convolucionales*”. En ejecución durante el periodo 2020 – 2021.

Dicho proyecto se inscribe dentro de la línea de investigación que lleva adelante un grupo de trabajo en la temática de Inteligencia Artificial y Visión Artificial orientado al control automático de procesos mineros, que se viene desarrollando hace varios años en el Instituto de Investigaciones Mineras de la Facultad de Ingeniería de la UNSJ.

A su vez, el mencionado proyecto representa la continuidad del proyecto “*Visión artificial aplicada a la determinación de propiedades geométricas de arenas de fracturación para el análisis de calidad*”, desarrollado durante 2018 y 2019.

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 *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 redes neuronales artificiales [2].

Se sabe que las redes neuronales artificiales 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 redes neuronales artificiales son aptas para resolver problemas que la gente puede resolver, pero las computadoras

no pueden, o los algoritmos resultan muy complicados [3].

El conocimiento es adquirido por la red a través de un proceso que se denomina aprendizaje [4]; 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].

Se habla de conjunto de datos, al utilizado para llevar a cabo la tarea de aprendizaje de la red neuronal, como así también para realizar las pruebas o validación. Existe cierta relación entre la cantidad de datos para el entrenamiento y la capacidad que adquiere la red para generalizar. Por lo general se subdivide el conjunto original en un subconjunto de datos para el entrenamiento y otro subconjunto para las pruebas.

Al utilizar redes neuronales, si necesitaráramos operar con imágenes, y realizar una clasificación teniendo en cuenta alguna característica, primero habría que extraer tales características del conjunto de imágenes y armar un conjunto nuevo conteniendo dichas características, y estas serían las entradas a utilizar por la red. Esto implica tener que realizar un trabajo previo de extracción de características y así poder contar con este conjunto nuevo de datos (características de interés), siendo utilizadas luego como subconjuntos de entrenamiento y de prueba.

Existen otro tipo 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 la o las características de interés, estas son las redes neuronales convolucionales [6].

Las redes neuronales convolucionales son especialmente útiles para localizar patrones en imágenes con el objetivo de reconocer

objetos, formas, etc. Aprenden directamente a partir de los datos de imágenes, utilizando patrones para clasificar las imágenes y eliminar la necesidad de una extracción manual de características [7].

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 componen de capas Convolucionales y de Pooling de forma alternada, Finalizando con una serie de capas de neuronas “completamente conectadas”.

En cuanto el proceso de extracción de petróleo mediante fracturación hidráulica, 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, utiliza las cartillas de *Krumbein y Sloss* para clasificarlas en cuanto a redondez y esfericidad, como se expone en la figura 1. Dicha tabla posee solamente 20 elementos gráficos de acuerdo a distintos valores de redondez y esfericidad. Tales elementos imágenes de partículas de arena de la tabla resultan extremadamente insuficientes si se quisieran utilizar para llevar a cabo el entrenamiento de la red neuronal. Además, la bibliografía consultada hace referencia que para el caso de las redes neuronales convolucionales se requieren un mayor número de elementos (imágenes) de entrenamiento que para otro tipo de Red Neuronal.




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

Por lo antes enunciado, se requiere contar con un conjunto o banco de imágenes capturadas por microscopio electrónico, y a su vez que las mismas se encuentren clasificadas en cuanto a medidas de Redondez y Esfericidad. Se requeriría aproximadamente entre 1000 y 10.000 elementos de acuerdo a la bibliografía consultada [6].

Dado que en la práctica esto resulta difícil de concretar, se propone una alternativa para el armado del conjunto de imágenes de partículas de arena, mediante el software matemático Matlab [7], generando partículas de arena que no son imágenes tomadas mediante un microscopio (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 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*.

En búsqueda de dar solución al tema de clasificación de partículas, se ha incorporado el trabajo con 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

Durante el año 2020 se ha trabajado en la elaboración del algoritmo y técnicas que permiten generar cada imagen de partícula de arena (artificial), para conformar el conjunto de entrenamiento y prueba de la Red Neuronal Convolutiva. Así también, se está trabajando en el diseño de la red neuronal y su implementación.

Tal como se observa de la figura 2, la entrada de la red neuronal se alimenta con las imágenes de las partículas de arena en forma directa (partículas gráficas generadas artificialmente para este caso particular). Esto trae como ventaja de que no deben extraerse

manualmente ni tampoco mediante algoritmos características de las imágenes para ser ingresadas a la red neuronal convolutiva. Posteriormente pasa a una capa de convolución y pooling, y así sucesivamente hasta extraer las características requeridas de cada imagen. Por último, se pasa a una red neuronal completamente conectada, ajustándose sus pesos sinápticos, durante la etapa de aprendizaje.

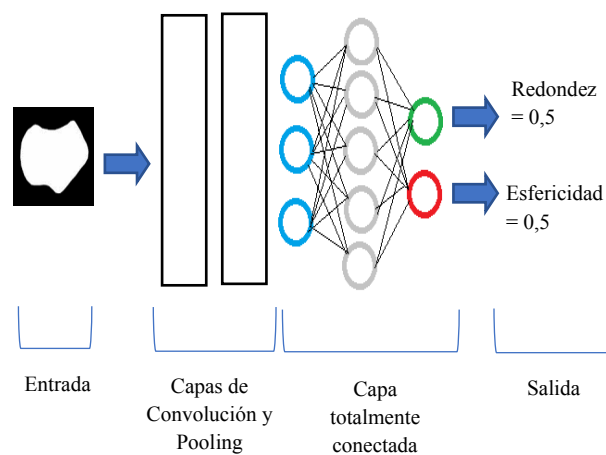


Figura 2. Diagrama de Red Neuronal Convolutiva para clasificar partículas de arena

Resulta importante que una vez entrenada y validada la red neuronal convolutiva, en la salida se obtienen los valores de redondez y esfericidad de cada imagen que se está analizando por parte de la red. Para el caso de ejemplo de la figura 1, para la partícula ingresada, si se recurre a la tabla 1 (cartilla de *Krumbein y Sloss*) se aprecia que una imagen de partícula de arena de aspecto similar efectivamente tiene un valor de redondez de 0,5, al igual que su esfericidad.

La figura 3 expone el algoritmo que elabora cada imagen artificial de partícula de arena. Sobre una imagen con fondo de color negro se grafica una serie de elipses y círculos, se determina la cantidad de elementos 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, obsérvese

la figura 4-A. Luego se aplica un filtro de bordes, de *Canny* específicamente [8], para poder trabajar solamente con el contorno resultante, figura 4-B.

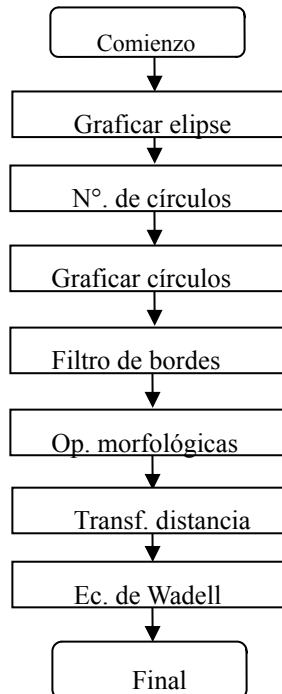


Figura 3. Algoritmo para graficar partículas artificiales de arena.

En la figura 4-C y 4-D se aplican 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.

Luego se realiza el cálculo de la transformada de distancia de la partícula obtenida lográndose el resultado de la figura 3-E.

Finalmente se calcula la redondez mediante la Ecuación 1 de *Wadell*, utilizando los radios de los círculos inscriptos en las esquinas de la partícula artificial, y tomando el valor de la transformada de distancia como el valor del radio del máximo círculo inscripto 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 3), 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).

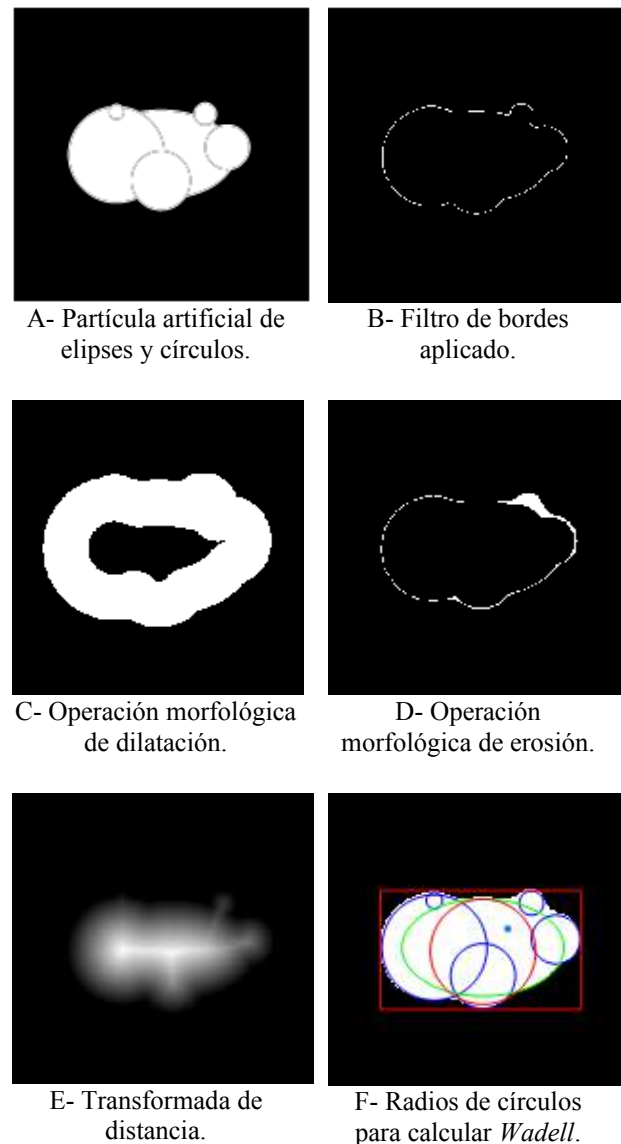


Figura 4. Resultados de aplicar el algoritmo para graficar partículas artificiales de arena.

Por lo antes expuesto, se ha desarrollado el algoritmo que permite generar partículas de arena, posibilitando la obtención de conjuntos de imágenes para el entrenamiento y testeo de la red neuronal convolucional. Así también se ha trabajado en el diseño de la red que se aplica para la clasificación de partículas de arenas con destino al *Fracking*.

Resta optimizar dicho diseño y llevar a cabo las pruebas necesarias para medir su desempeño, seguida de los correspondientes ajustes.

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 integrante comenzó en este grupo hace unos años participando de un proyecto PROJOVI (Proyecto de Jóvenes Investigadores), para luego continuar su participación en proyectos PIC (Proyecto de Investigación y Creación) en el periodo 2018 – 2019 y 2020-2021.

También, un alumno avanzado de la carrera de grado de Ingeniería en Electrónica, ha comenzado a participar del proyecto PIC en ejecución, 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] Rodriguez Medina, C. G.; Chuk, O. D.; Bertero R.; Luna, A.; Núñez, E.; Quinteros, D. 2020. Clasificación de partículas de arena de fracturación mediante redes neuronales convolucionales. Universidad Nacional de San Juan. Informe de Avance de Proyecto PIC.

[7] Mathworks. (1994-2019). Image Processing Toolbox. https://es.mathworks.com/products/image.html?s_tid=srchtitle.

[8] 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.