

# ***Granulometric analysis of aggregate for concrete through an algorithm based on neural networks (Deep Learning)***

## **Análisis granulométrico de agregado para el concreto a través de un algoritmo basado en redes neuronales (Deep Learning)**

Gutierrez Layme, Delia \* <https://orcid.org/0009-0002-3650-7316>

Lopez Hinostrroza, Hamhit \*

Sosa Aquisé, Rubén \* 1 <https://orcid.org/0000-0003-1058-828>

\* Universidad Peruana Unión, Lima, PERÚ.

Fecha de Recepción: 15/03/2023

Fecha de Aceptación: 18/07/2023

Fecha de Publicación: 30/12/2023

PAG: 448-460

### ***Abstract***

*Currently, the traditional mix design fails to adequately optimize the times involved. Therefore, it is proposed to use the neural network method to improve efficiency in terms of time and access to difficult places, as well as transport to the laboratory. The main objective is to apply deep learning techniques to evaluate the quality of a quarry aggregate and determine if it meets the specifications required for its specific use, in accordance with current regulations. The methodology consisted of collecting 20 images per sample, obtaining the granulometry analysis, 2 quarries from the department of Junín Satipo (Sonomoro and Llaylla) and 1 quarry from the department of Cusco (Vicho) were considered, with a total of 13 samples, in The present article carried out is located within a type of experimental research with a quantitative approach. The results were obtained through the execution of the Yolo algorithm, with image detection, obtaining 93.20%, according to the Peruvian technical standard (NTP 400.12, 2001), with a standard deviation of 0.96%. The algorithm was trained according to the sieves given in the Peruvian technical standard (NTP 350.001, 1970). In conclusion, the use of the algorithm in the data analysis has allowed to significantly reduce the time required to carry out the physical evaluation and has effectively improved the study of the aggregate.*

**Keywords:** *Aggregate; algorithm; granulometry; neural network.*

### **Resumen**

En la actualidad, el diseño de mezclas tradicional no logra optimizar adecuadamente los tiempos involucrados. Por lo tanto, se propone utilizar el método de las redes neuronales para mejorar la eficiencia en términos de tiempo y acceso a lugares difíciles, así como en el transporte al laboratorio. El objetivo principal es aplicar técnicas de aprendizaje profundo (deep learning) para evaluar la calidad de un agregado de cantera y determinar si cumple con las especificaciones requeridas para su uso en concreto, de acuerdo con las normativas vigentes. La metodología consistió en recopilar 20 imágenes por muestra, la obtención del análisis de granulometría, se consideró 2 canteras del departamento de Junín Satipo (Sonomoro y Llaylla) y 1 cantera del departamento de Cusco (Vicho), con un total de 13 muestras, en el presente artículo realizado se ubica dentro tipo de investigación experimental con un enfoque cuantitativo. Los resultados se obtuvieron a través de la ejecución del algoritmo Yolo, con la detección de imágenes, obteniendo el 93.20%, según la norma técnica peruana (NTP 400.12, 2001), con una desviación típica de 0,96 %. El algoritmo fue entrenado según los tamices dados en la norma técnica peruana (NTP 350.001, 1970). En conclusión, el uso del algoritmo en el análisis de los datos ha permitido reducir significativamente el tiempo requerido para llevar a cabo la evaluación física y ha mejorado el estudio del agregado de manera efectiva.

**Palabras clave:** Agregado; algoritmo; granulometría; red neuronal.

---

### ***Corresponding author:***

Universidad Peruana Unión, Lima, PERÚ.

E-mail: [ruben.sosa@upeu.edu.pe](mailto:ruben.sosa@upeu.edu.pe)

# 1. Introducción

La ingeniería y áreas afines son un factor decisivo en la creación de soluciones prácticas que abordan los desafíos de la sociedad. Estas soluciones tienen un efecto positivo en la calidad de vida de las personas. (Universidad Central de Venezuela, 2013).

El uso del hormigón como material de construcción es muy extendido, y su mezcla se compone fundamentalmente de cemento, agregados (tanto gruesos como finos), agua y aditivos, según señala (Verian et al., 2018). De acuerdo con (Kumar et al., 2021), las propiedades de los agregados tienen una gran influencia en las características del concreto, ya que estos constituyen alrededor del 70% al 80% del volumen del material.

Las imágenes digitales, se están utilizando en varios campos como la medicina, las industrias de defensa y espaciales, la teledetección y la agricultura. (Azizi et al., 2020).

Teniendo en cuenta la profundidad de bits, se puede decir que una imagen es una matriz de números, que se pueden aplicar diversas operaciones y algoritmos matemáticos. Por lo tanto, dependiendo del tipo de aplicación y el objetivo esperado, esto se denomina procesamiento de imágenes. (Azizi et al., 2020). El algoritmo tiene la misma precisión que un proceso de conteo manual clásico, pero la aplicación de esta metodología innovadora es mucho más fácil y requiere mucho menos tiempo. (Chávez et al., 2015).

El objetivo de esta investigación es desarrollar una técnica de imágenes que permita el análisis cuantitativo de la distribución del tamaño de los agregados del concreto. Si se logra desarrollar dicha técnica, podría convertirse en una herramienta valiosa para la evaluación rápida de la granulometría de los agregados.

El problema que se pretende resolver, consiste en la clasificación granulométrica de un material que no se tiene información precisa de sus características, siendo esto una información fundamental en la ingeniería. Debido a que este ensayo granulométrico no es fácil de realizar, porque se tiene que tener un laboratorio especializado y la accesibilidad a este tiene que ser en la ciudad, conlleva a que los resultados se obtengan tarde y las zonas donde se realizan los proyectos son en zonas rurales donde el transporte es dificultoso.

# 2. Metodología

La investigación se realizó esta dentro del tipo de investigación experimental con un enfoque cuantitativo

## 2.1 Proceso de Algoritmo

### 2.1.1 Modelo de Aprendizaje Profundo

Se utilizó principalmente el algoritmo de aprendizaje profundo YOLO, complementado con la librería de visión computacional OPENCV, para lograr un resultado óptimo en la investigación. Es una red convolucional única que realiza predicciones simultáneas de múltiples cuadros delimitadores y probabilidades de clase para esos cuadros. Divide la imagen de entrada en una cuadrícula  $S \times S$ , si el objeto está en el centro de una celda de la cuadrícula, esa celda es responsable de detectar el objeto. Además, entrena con imágenes completas y optimiza directamente el rendimiento de detección. Además, puede procesar video en tiempo real con menos de 25 milisegundos de latencia, lo que lo hace muy eficiente. (Pérez et al., 2019).

OpenCV es una biblioteca de visión artificial que inicialmente fue desarrollada por la empresa Intel. Se enfoca en el procesamiento de imagen en tiempo real y es de código abierto y multiplataforma, lo que significa que puede ser utilizado en Mac OSX, Windows y Linux. Contiene más de 500 funciones que cubren una amplia gama de áreas de procesamiento de visión, como reconocimiento facial, calibración de cámaras y visión robótica. (Sugue, 2020).




Figura 1. Sistema del algoritmo YOLO

## 2.2 Etapa 2: Análisis Estadístico

La (Figura 1) muestra la arquitectura del sistema YOLO, que se utiliza para la detección de objetos a través de un enfoque de regresión única. Esto significa que el algoritmo va desde los píxeles de la imagen hasta las coordenadas del cuadro delimitador en una

ENGLISH VERSION.....

sola tarea de regresión. Este sistema se utiliza para detectar objetos en imágenes y videos, y se basa en una red neuronal convolucional para realizar la tarea de detección. (Erazo and Navarrete, 2022).

### 2.1.2 Adquisición de Imagen

La adquisición de las imágenes de los cambios en la luz ambiental permitió que las imágenes se hicieran en condiciones reales, ya sea en días soleados o nublados, en este estudio, se utilizó una cámara móvil equipada con la cámara principal de 13MP. La distancia entre la lente de la cámara es de 60 centímetros, previamente el agregado este lavado y secado, siendo esto necesario para su clasificación de los agregados para concreto.

Así también (De La Cruz et al., 2020) utilizó este método, para la clasificación de imágenes, la agrupación por similitud (búsqueda de fotos) y el reconocimiento de objetos.




Figura 2. Imágenes previo lavado y secado

La (Figura 2), muestra imágenes de cada tamiz pasante, para luego ser procesado mediante el algoritmo yolo.

### 2.1.3 Categorización de imágenes

Para la categorización de imágenes de la base de datos. Se utilizó un software de nombre LabelImg que es una herramienta, argumenta (Goodfellow et al., 2016). Está escrito en Python, se usó para etiquetar cada una de la toma, que dentro de ellas se visualizó los distintos tamices.

Una vez que la imagen fue previamente marcada con LabelImg, esta herramienta produce una serie del archivo para cada imagen en la carpeta se llama Etiqueta. Una vez tienes sus respectivas imágenes archivos (.txt) Estos deben ser ubicados en la carpeta de train, con el mismo en la raíz de la carpeta donde se trabajó, para luego ser utilizados en la fase de entrenamiento.

## 2.2 Redes neuronales (Depp Learning)

Las redes neuronales del tipo visión multicapa son concluyentes y han mostrado una mejor capacidad clasificatoria igual o superior que los análisis o técnicas estadísticos. Se expresa que con el tiempo los programas (SPSS, MATLAB, ETC), vendrán incorporados con módulos de redes neuronales. (Pitarque et al., 1991).

## 2.3 Entrenamiento del algoritmo

Para esta fase se trabajó con la herramienta de Google colab, que está enlazada con el Google drive, dicha herramienta nos otorga ciertas ventajas las cuales son un mejor rendimiento de GPU (unidad de procesador gráfico), otra ventaja es el trabajo en la nube.

Antes de empezar el entrenamiento se tuvo que crear un archivo de formato. ipynb (extensión del archivo) donde se ejecutará todo el algoritmo programado. Como primera instancia se le dio acceso a dicho archivo las carpetas del google drive para extraer la data de entrenamiento con el siguiente comando "drive.mount ('/content/drive')", luego se procede a descargar del repositorio Github lo archivos necesarios de YOLO, por último para empezar el entrenamiento se procede a insertar el siguiente comando:

```
!python train.py --img 640 --batch 16 --epochs 100 --data customdata.yaml --weights yolov5s.pt --cache.
```

- Train.py: contiene el símbolo preciso para el entrenamiento.
- Img: es el tamaño con el cual mostraremos los resultados del entrenamiento.
- Epochs 100: son la cantidad de épocas que realizará el algoritmo para el entrenamiento.
- Data: Es el archivo que contiene la dirección de imágenes hacia el entrenamiento.
- yolov5s.pt: es el formato donde se compila el algoritmo al terminar el entrenamiento.

```

Epoch  gpu_mem  box  obj  cls  labels  img_size
94/99   3.48G  0.07806  0.112  0.04192  312  640: 100% 2/2 [00:00<00:00, 5.23it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.23it/s]
      all    10      324    0.213  0.304  0.0988  0.0501

Epoch  gpu_mem  box  obj  cls  labels  img_size
95/99   3.48G  0.07895  0.1212  0.04153  469  640: 100% 2/2 [00:00<00:00, 4.88it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.27it/s]
      all    10      324    0.214  0.304  0.101  0.0509

Epoch  gpu_mem  box  obj  cls  labels  img_size
96/99   3.48G  0.07689  0.1219  0.04203  620  640: 100% 2/2 [00:00<00:00, 5.02it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.29it/s]
      all    10      324    0.217  0.304  0.102  0.0505

Epoch  gpu_mem  box  obj  cls  labels  img_size
97/99   3.48G  0.07771  0.1167  0.04127  438  640: 100% 2/2 [00:00<00:00, 5.13it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.56it/s]
      all    10      324    0.217  0.303  0.102  0.0508

Epoch  gpu_mem  box  obj  cls  labels  img_size
98/99   3.48G  0.0785  0.1177  0.0425  410  640: 100% 2/2 [00:00<00:00, 5.24it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.30it/s]
      all    10      324    0.218  0.303  0.102  0.0513

Epoch  gpu_mem  box  obj  cls  labels  img_size
99/99   3.48G  0.0759  0.09862  0.03952  289  640: 100% 2/2 [00:00<00:00, 5.01it/s]
      Class  Images  Labels  P      R      mAP@.5  mAP@.5:.95: 100% 1/1 [00:00<00:00, 3.41it/s]
      all    10      324    0.219  0.306  0.103  0.0508
    
```

**Figura 3.** Entrenamiento del algoritmo

La (Figura 3) muestra que el entrenamiento se realiza en 100 iteraciones, tal como se había especificado previamente como parámetro, cabe recalcar que el entrenamiento tiene un mejor desempeño al ejecutarse en un entorno con GPU (unidad de procesador gráfico), a diferencia de poder ejecutarlo en un entorno donde solo se cuenta con CPU, si ese es el caso el entrenamiento tomará mucho más tiempo de lo esperado.

(Brownlee, 2018), menciona que, si se utilizan demasiadas épocas para entrenar un modelo, puede producirse un sobreajuste en los datos de entrenamiento, mientras que muy pocas épocas pueden generar un modelo insuficiente. La técnica de detección temprana permite establecer un número determinado de épocas de entrenamiento y detener el proceso cuando el rendimiento del modelo deja de mejorar en un conjunto de datos de validación previamente establecidos.

### 2.3.1 Detección de tamiz con OPENCV

En la fase es donde se obtienen todos los datos detectados por el algoritmo de YOLO, el conteo de objetos encontrados es según el color por cada tamiz, debido a que no se puede hacer dicho conteo. (Ribeiro, 2020)

## 3. Análisis Estadístico

### 3.1 Análisis de T student

(William, 2015), desarrolló la prueba t y la distribución t. La prueba de Student es una herramienta estadística utilizada para comparar los medios de dos grupos independientes y determinar si hay una diferencia significativa entre ellos. (Tabla 1).

**Tabla 1.** %Peso Retenido

% PESO RETENIDO			
TAMI Z	ABERT. mm.	M. SONOMORO	M. LLAYLLA
T1/2"	12.7	90.255	17.764
T3/8"	9.525	89.200	94.000
T4	4.76	290.100	40.000
T8	2.36	205.900	34.250
T16	1.18	100.000	100.000
T30	0.6	600.000	600.000
T50	0.3	290.000	290.000
T100	0.15	100.000	100.000
T200	0.075	28.000	28.000

**Tabla 2.** Resumen de valores estadísticos descriptivos de las canteras Sonomoro y Llaylla

RESUMEN DE VALORES ESTADÍSTICOS		
	SONOMORO	LLAYLLA
U	600	600
Promedio (X)	199.273	144.890
Desviación Estandar (S)	269.124	238.883
Nivel de Significancia	0.025	
Grado de Confianza	97.50%	
N (Grado de Libertad)	16	

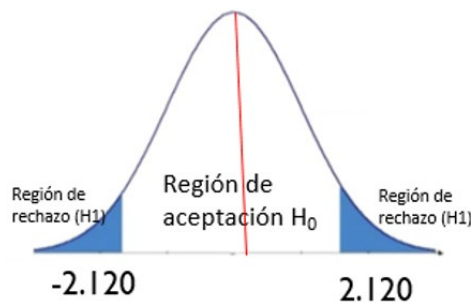
a.- Planteamiento de la prueba de hipótesis, conforme a la prueba estadística de T- STUDENT se formulan la hipótesis nula y la hipótesis alternativa, para responder a la pregunta: ¿la hipótesis nula establece que no hay diferencias de ambas muestras, la hipótesis alternativa indica que si hay diferencia?

$$H_0: u > 600$$

$$H_1: u < 600$$

b.- Nivel de significancia:  $\alpha = 2.50 \%$

c.- De la tabla estadística (Tabla 2) con un nivel de confianza del 97.5 % y 16 grados de libertad ( $n_1+n_2-2$ ), una prueba de dos colas, se obtiene el valor de  $t = 2.120$  y  $t = -2.120$  (Figura 4).



**Figura 4.** Distribución de  $t$   
 $t = 2.120$

Según la fórmula de  $t$  Student resulta (Ecuación 1):

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{S_c^2}{n_1} + \frac{S_c^2}{n_2}}} \quad (1)$$

$$T = 0.629$$

Por lo tanto, tomamos la siguiente decisión, la hipótesis nula  $H_0$  se acepta ya que  $t = 0.629$  se encuentra en la región entre  $-2.120$  y  $2.120$  y la hipótesis alterna se rechaza.

(Sampieri et al., 1991), En acuerdo a la probabilidad ( $p$ -valor) obtenido, observamos que es mayor al nivel de significancia ( $\alpha$ ), por ende, aceptamos la hipótesis nula y rechazamos la hipótesis alternativa, concluyendo además que, no existe diferencias significativas entre las medias de las muestras.

## 4. Resultados

Se realizó la granulometría según la (NTP 400.12, 2001), de las canteras de Llaylla, Sonomoro y Vicho con un total de 13 muestras, utilizando las cantidades entre  $\frac{1}{2}$  kg a  $1 \frac{1}{2}$  kg las que fueron ensayados en el laboratorio para concreto, se obtuvo el resultado de granulometría, siendo estas mismas muestras utilizadas para las capturas de imagen para el entrenamiento del algoritmo, obteniendo como resultado en ambos casos lo siguiente:

**Tabla 3.** Peso retenido de la cantera de Sonomoro

ENGLISH VERSION.....

PESO RETENIDO CANTERA SONOMORO					
	M1S	M2S	M3S	M4S	M5S
TAMIZ	PS. RT.	PS. RT.	PS. RT.	PS. RT.	PS. RT.
3"	-	-	-	-	-
2 1/2"	-	-	-	-	-
2"	-	-	-	-	-
1 1/2"	-	-	-	-	-
1"	-	-	-	-	-
3/4"	-	-	-	-	-
T1/2"	67.564	98.273	104.709	100.327	80.400
T3/8"	48.000	5.000	2.000	118.000	273.000
T4	203.500	328.500	235.500	323.500	359.500
T8	181.000	225.500	177.000	231.250	214.750
T16	100.000	100.000	100.000	100.000	100.000
T30	600.000	600.000	600.000	600.000	600.000
T50	290.000	290.000	290.000	290.000	290.000
T100	100.000	100.000	100.000	100.000	100.000
T200	28.000	28.000	28.000	28.000	28.000
-	29.000	29.000	29.000	29.000	29.000
<b>TOTAL</b>	<b>1618.064</b>	<b>1775.273</b>	<b>1637.209</b>	<b>1891.077</b>	<b>2045.650</b>

Donde:

M1S, M2S, M3S, M4S y M5S; son las 5 muestras de la cantera de Sonomoro.

En la (Tabla 3), se obtuvieron los resultados de peso retenido total que son, M1S= 1618.064 gr, M2S= 1775.273 gr, M3S= 1637.209 gr, M4S= 1891.077 gr, M5S= 2045.650 gr. A través del algoritmo yolo.

Se registró la sumatoria total de cada muestra pasante en cada tamiz, para determinar el porcentaje en cada una de las muestras realizadas, usamos la siguiente fórmula (Ecuación 2).

$$\% \text{Retenido Parcial} = \frac{\text{Peso Retenido} \times 100}{\text{Peso de la Muestra Total}} \quad (2)$$

Tabla 4. % Peso retenido de la cantera de Sonomoro

% PESO RETENIDO					
	M1S	M2S	M3S	M4S	M5S
<b>PESO INICIAL</b>	1774.000	1889.000	1868.000	1859.000	1885.000
<b>PESO RETENIDO</b>	1618.064	1775.273	1637.209	1891.077	2045.650
<b>%</b>	91.2 %	94.0 %	87.7 %	101.7 %	108.5 %

En la (Tabla 4), se obtuvieron los resultados de % peso retenido de cada muestra que son, M1S= 91.20 %, M2S= 94.0 %, M3S= 87.7 %, M4S= 101.7 %, M5S= 108.5 %.

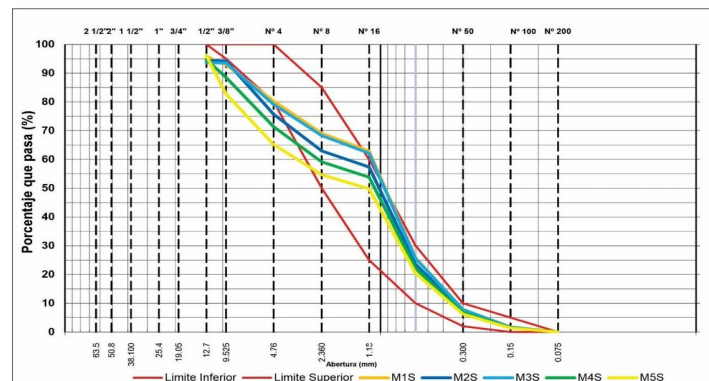


Figura 5. Curva Granulométrica de la cantera de Sonomoro

La (Figura 5), muestra la curva granulométrica, teniendo un límite inferior y superior, de las cuales las líneas al llegar al pasante N° 16 se encuentran en su punto crítico.

**Tabla 5. Peso retenido de la cantera de Llaylla**

PESO RETENIDO CANTERA LLAYLLA					
	M1L	M2L	M3L	M4L	M5L
Tam	PS. RT.	PS. RT.	PS. RT.	PS. RT.	PS. RT.
3"	-	-	-	-	-
2 1/2"	-	-	-	-	-
2"	-	-	-	-	-
1 1/2"	-	-	-	-	-
1"	-	-	-	-	-
3/4"	-	-	-	-	-
T1/2"	20.000	14.455	11.418	26.491	16.455
T3/8"	160.000	0.000	20.000	155.000	135.000
T4	48.000	71.500	28.000	40.000	12.500
T8	35.250	45.000	50.000	26.750	14.250
T16	100.000	100.000	100.000	100.000	100.000
T30	600.000	600.000	600.000	600.000	600.000
T50	290.000	290.000	290.000	290.000	290.000
T100	100.000	100.000	100.000	100.000	100.000
T200	28.000	28.000	28.000	28.000	28.000
-	29.000	29.000	29.000	29.000	29.000
<b>TOTAL</b>	<b>1381.250</b>	<b>1248.955</b>	<b>1227.418</b>	<b>1366.241</b>	<b>1296.205</b>

Donde:

M1L, M2L, M3L, M4L y M5L; son las 5 muestras de la cantera de Llaylla.

En la (Tabla 5), se obtuvieron los resultados de peso retenido total que son, M1L= 1381. 250 gr, M2L= 1248.955 gr, M3L= 1227.418 gr, M4L= 1366.241 gr, M5L= 1296.205 gr. A través del algoritmo yolo.


Se registró la sumatoria total de cada muestra pasante en cada tamiz, para determinar el porcentaje en cada una de las muestras realizadas, usamos la siguiente fórmula (Ecuación 3).

$$\% \text{Retenido Parcial} = \frac{\text{Peso Retenido} \times 100}{\text{Peso de la Muestra Total}} \quad (3)$$

**Tabla 6. % Peso retenido de la cantera de Llaylla**

% PESO RETENIDO					
	M1L	M2L	M3L	M4L	M5L
<b>PESO INICIAL</b>	1506.000	1455.000	1392.000	1440.000	1468.000
<b>PESO RETENIDO</b>	1381.250	1248.955	1227.418	1366.241	1296.205
<b>%</b>	91.7 %	85.8 %	88.2 %	94.9 %	88.3 %

En la (Tabla 6), se obtuvieron los resultados de % peso retenido de cada muestra que son, M1L= 91.7 %, M2L= 85.8 %, M3L= 88.20 %, M4L= 94.9 %, M5L= 88.30 %.



**Figura 6. Curva Granulométrica de la cantera de Llaylla**

La (Figura 6), muestra la curva granulométrica, teniendo un límite inferior y superior, de las cuales las líneas al llegar al pasante N° 16 se encuentran en su punto crítico.

Según la (NTP 400.12, 2001), el uso del algoritmo, para el análisis de la curva granulométrica puede ser una herramienta útil para la ingeniería civil, pero es importante tener en cuenta los límites y la validación experimental necesaria para obtener resultados precisos y confiables.

**Tabla 7. Peso retenido de la cantera de Vicho**

PESO RETENIDO CANTERA VICHO			
	M1V	M2V	M3V
Tmz	PS. RT.	PS. RT.	PS. RT.
3"	-	-	-
2 1/2"	-	-	-
2"	-	-	-
1 1/2"	-	-	-
1"	-	-	-
3/4"	-	-	-
T1/2"	13.436	230.509	157.436
T3/8"	14195.000	3839.000	3185.000
T4	2977.500	4572.000	2316.000
T8	1600.750	2461.500	1671.000
T16	100.000	100.000	100.000
T30	600.000	600.000	600.000
T50	290.000	290.000	290.000
T100	100.000	100.000	100.000
T200	28.000	28.000	28.000
-	29.000	29.000	29.000
<b>TOTAL</b>	<b>19904.686</b>	<b>12221.009</b>	<b>8447.436</b>

Donde:

M1V, M2V, M3V, M4V y M5V; son las 3 muestras de la cantera de Vicho.

En la (Tabla 7), se obtuvieron los resultados de peso retenido total que son, M1V= 19904.686 gr, M2V= 12221.009 gr, M3V= 8447.436 gr. A través del algoritmo yolo.


%Retenido Parcial=(Peso Retenido x 100)/(Peso de la Muestra Total) (Ecuación 4)

$$\% \text{Retenido Parcial} = \frac{\text{Peso Retenido} \times 100}{\text{Peso de la Muestra Total}} \quad (4)$$

**Tabla 8. % Peso retenido de la cantera Vicho**

% PESO RETENIDO			
	M1V	M2V	M3V
<b>PESO INICIAL</b>	1422.000	1407.000	1386.000
<b>PESO RETENIDO</b>	19904.686	12221.009	8447.436
<b>%</b>	<b>1399.8 %</b>	<b>868.6 %</b>	<b>609.5 %</b>

En la (Tabla 8), se obtuvieron los resultados de % peso retenido de cada muestra que son, M1V= 1399.8 %, M2V= 868.6 %, M3V= 609.5 %.



**Figura 7. Curva Granulométrica de la cantera de Vicho**

La (Figura 7), muestra la curva granulométrica, teniendo un límite inferior y superior, de las cuales las líneas se encuentran debajo del límite inferior.

En las (Tabla 4 y (Tabla 6) obtuvimos los porcentajes % de cada cantera, Sonomoro y Llaylla. Los resultados están de acuerdo a la norma técnica (NTP 400.12, 2001), para obtener el promedio de porcentaje aplicamos la siguiente fórmula (Ecuación 5).



$$Promedio = \frac{\sum \text{Peso Retenido}}{\text{Cantidad de Muestras}} \quad (5)$$

| Es muy bueno saber que los resultados obtenidos están dentro de los parámetros establecidos por la norma técnica (NTP 400.12, 2001) y que el algoritmo utilizado pudo estimar correctamente la distribución granulométrica de las dos canteras Sonomoro y Llaylla con una desviación típica del 0,96 %.

**Tabla 9.** Peso retenido en laboratorio y peso retenido con el algoritmo

	PS. RT.	
	GRANULOMETRÍA LABORATORIO DE CONCRETO	GRANULOMETRÍA CON ALGORITMO
M1S	1774.000	1618.064
M2S	1889.000	1775.273
M3S	1868.000	1637.209
M4S	1859.000	1891.077
M5S	1885.000	2045.650
M1L	1506.000	1381.250
M2L	1455.000	1248.955
M3L	1392.000	1227.418
M4L	1440.000	1366.241
M5L	1466.000	1296.205
M1V	1422.800	19904.686
M2V	1407.100	12221.009
M3V	1386.600	8447.436

La (Tabla 9) presenta los PS. RT. de 13 muestras, ejecutadas en laboratorio y el algoritmo.

La obtención de las imágenes fue tomada con el agregado lavado y seco, estos mismos fueron colocados en una bandeja de 66cm de largo, 47cm ancho y 6.5cm de altura, se utilizó una cámara móvil equipada con la cámara principal de 13MP. La distancia de 60 cm entre la lente de la cámara y la muestra parece ser adecuada para garantizar que las imágenes sean claras y nítidas, lo que es importante para un análisis preciso. Es importante asegurarse de que la cámara esté enfocada correctamente en la muestra para garantizar la precisión de los datos recopilados.

La caracterización granulométrica alcanzó el 93,20 %. Este resultado se obtiene al ejecutarlo con 100 iteraciones en el algoritmo, la cual juegan un papel clave en las técnicas basadas en el aprendizaje.


Es crucial monitorear el rendimiento del modelo durante el entrenamiento y validar regularmente el modelo para evitar el sobreajuste y garantizar que el modelo pueda generalizar y predecir con precisión nuevos datos. (Greyrat, 2022).

## 5. Discusión

El algoritmo fue entrenado con 3 canteras; Sonomoro, Llaylla y Vicho, siendo un total de 13 muestras extraídas, con 260 imágenes, se identificó los tamaños de cada agregado según los tamices dadas en la (NTP 350.001, 1970), de acuerdo a las características color, forma y peso, dando resultado a obtener la granulometría con el algoritmo entrenado, se considera con mayor precisión a las canteras de Sonomoro y Llaylla.

La cantera de vicho, no cumple con los parámetros porque obtuvo resultados que no están dentro del rango como indica la (NTP 400.12, 2001).

"Google Colaboratory", también conocido como "Google Colab" o "Colab", es un proyecto de investigación que busca prototipos para crear modelos de aprendizaje automático utilizando hardware de alto rendimiento como GPU y TPU. Ofrece un entorno de desarrollo interactivo sin servidor basado en notebooks Jupyter. (Bisong, 2019).



**Figura 8.** Detección de imágenes

Según lo ilustrado en la (Figura 8), se obtuvo la detección de imágenes con el algoritmo. (De La Cruz et al., 2020), menciona que los datos de entrenamiento son como un recurso que se adapta en el entrenamiento CNN, el objetivo de aprendizaje es lo que se espera que aprenda la Red Neuronal Artificial.

**Tabla 10. %Peso Retenido del algoritmo y laboratorio**

% PESO RETENIDO							
TAMIZ	ABERT. mm.	ALGORITMO			LABORATORIO		
		M. SONOMORO	M. LLAYLLA	M. VICHO	M. SONOMORO	M. LLAYLLA	M. VICHO
3"	76.2	-	-	-	-	-	-
2 1/2"	63.5	-	-	-	-	-	-
2"	50.8	-	-	-	-	-	-
1 1/2"	38.1	-	-	-	-	-	-
1"	25.4	-	-	-	-	-	-
3/4"	19.05	-	-	-	15.930	-	-
T1/2"	12.7	90.255	17.764	133.794	119.340	8.356	-
T3/8"	9.525	89.200	94.000	7073.000	66.334	12.876	3.100
T4	4.76	290.100	40.000	3288.500	196.216	35.090	377.600
T8	2.36	205.900	34.250	1911.083	210.014	141.114	375.733
T16	1.18	100.000	100.000	100.000	201.938	301.054	245.000
T30	0.6	600.000	600.000	600.000	648.240	590.640	99.633
T50	0.3	290.000	290.000	290.000	250.048	251.738	82.000
T100	0.15	100.000	100.000	100.000	106.028	87.018	54.133
T200	0.075	28.000	28.000	28.000	24.242	13.588	30.900
-	FONDO	29.000	29.000	29.000	29.414	10.726	138.433
<b>TOTAL</b>		<b>1793.455</b>	<b>1304.014</b>	<b>13524.377</b>	<b>1867.744</b>	<b>1452.200</b>	<b>1406.533</b>

En la (Tabla 10), se tiene una diferencia entre el algoritmo y el laboratorio teniendo estos valores. En Sonomoro hay un % porcentaje de peso retenido total de 1793.455gr y 1867.744 gr, con una diferencia del 4%, Llaylla 1304.014 gr y 1452.200 gr, con el 10 % de diferencia, Vicho 13524.377 gr y 1406.533 gr. -862 % de diferencia. Por tanto, para el estudio se usó las canteras de Sonomoro, Llaylla y la cantera de Vicho no se utilizó porque el resultado no es coherente a raíz de la toma de fotografías.

**Tabla 11. Precisión**

	Porcentaje Total de material que pasa	Desviación Típica (1s), %	Rango aceptable de dos Resultados (d2s), %
<b>Agregado Grueso</b>			
	< 100	≥ 95	0,32
	< 95	≥ 85	0,81
	< 85	≥ 80	1,34
	< 80	≥ 60	2,25
	< 60	≥ 20	1,32
	< 20	≥ 15	0,96
	< 15	≥ 10	1,00
	< 10	≥ 5	0,75
	< 5	≥ 2	0,53
	< 2	> 0	0,27
<b>Precisión de un operador</b>			

Según la norma técnica (NTP 400.12, 2001), nos muestra una tabla de precisión tal como está en la (Tabla 11). Indicando una desviación típica en relación al suelo que se va a construir, para la resistencia a compresión.

El estudio se realizó de canteras de ríos, establece que la cantera es la fuente de suministro de suelos y rocas utilizados para construir una obra afirma (Herrera, 2007).

Según (Soto, 2017), el algoritmo yolo abarca para cualquier tipo de cantera, ya que solo se necesita imágenes. Se trata de un sistema de detección de objetos en tiempo real de última generación de código abierto que utiliza una red neuronal convolucional para identificar objetos únicos en imágenes.

El algoritmo es capaz de aprender representaciones generales de objetos, lo que se traduce en un bajo margen de error en la detección de nuevas entradas que no forman parte del conjunto de datos de entrenamiento. (Soto, 2017).

(Capistrán, 2020), considera que la detección de imágenes por medio del algoritmo de YOLO es una manera precisa y segura de trabajar. (Ribeiro, 2020), aplicó en su investigación métodos de evaluación de desempeño para validar la detección de imágenes a través de la visión artificial.

**Tabla 12. Matriz de confusión**

		Condición Prevista	
		VERDADERO	FALSO
CONDICIÓN	VERDADERO	Verdaderos Positivos (VP)	Falso Positivos (FP)
	FALSO	Falso Negativos (FN)	Verdadero Negativo (VN)

(Barrios, 2019), realizó los cálculos de exactitud y precisión. Son métricas que miden y validan el algoritmo aplicado. (Barrios, 2019), inserta datos para cada valor requerido para el cálculo y esta investigación aplicó la misma metodología. Reemplazando datos obtenidos del algoritmo yolo y de laboratorio, que viene a hacer los pesos retenidos. (Tabla 12).

- Tiene redes neuronales y sale positivo – VP= 96.62%
- No tiene redes neuronales (laboratorio) y sale negativo – FP= 100 %
- Tiene redes neuronales y sale negativo – FN= 89.78 %
- No tiene redes neuronales (laboratorio) y sale positivo – VN=100%

Para ellos se calcula lo siguiente:

Exactitud (Ecuación 6):

$$E = \frac{VP + VN}{(VP + FP + FN + VN)}$$

$$E = \frac{96.92 + 100}{(96.62 + 100 + 89.78 + 100)}$$

$$E = 51.00 \% \tag{6}$$


Precisión (Ecuación 7):

$$P = \frac{VP}{(VP + FP)}$$

$$P = \frac{96.92}{(96.62 + 89.78)}$$

$$P = 51.83 \% \tag{7}$$

(Madrigal, 2022), afirma que es fundamental la precisión en los datos de entrenamiento del algoritmo, ya que el resultado debe ser confiable.



**Figura 9. Precisión y exactitud**

(Madrigal, 2022), dice que, si la métrica es correcta, no hay necesidad de buscar otra, porque ya se ajusta mejor el conjunto. (Figura 9).

Según (Muñoz, 2019), si la ventana de captura es demasiado grande, es posible que los fragmentos más grandes sean fácilmente distinguibles, pero los fragmentos más pequeños no podrán ser analizados en la misma imagen debido a que la resolución y el enfoque de la imagen limitan su detección.




Figura 10. Precisión y exactitud

(Barrios, 2019), dice que la precisión es un gran estadístico cuando se tiene una cantidad de datos con valores similares y la exactitud en términos de medición de obtención de un valor verdadero. (Figura 10).

Los resultados son válidos cuando la precisión y exactitud estén acorde a la aceptación correcta cuando el tamaño de imagen y los píxeles sean correctos. (Barrios, 2019), afirma que cuando menos es la dispersión mayor es la precisión.

(Benites, 2022), explica que, en granulometría, el error absoluto se define como la diferencia existente entre el valor medido y el valor real, y especifica que existe un algoritmo específico para calcularlo (Ecuación 8).

$$\begin{aligned}
 (\Delta x) &= x_{yo} - x, \\
 (\Delta x) &= 93.20\% - 100\% \\
 (\Delta x) &= -6.80\%
 \end{aligned}
 \tag{8}$$

Donde:

- $x_i$  es la medida,
- $x$  es el valor verdadero.

(Benites, 2022), afirma que, si el valor de error absoluto es negativo, está bien.

## 6. Conclusiones

Se concluye que la información recopilada, puede ser mejorada mediante mejores tomas de imágenes y así tener un buen estudio granulométrico mediante redes neuronales y mejorar la calidad del concreto. La validación del algoritmo mediante estudios realizados y resultados obtenidos en laboratorio, precisa la determinación de los análisis granulométricos, con un porcentaje de 93.20% de acuerdo a la (NTP 400.12, 2001) y una desviación típica del 0.96%. Los resultados obtenidos en esta investigación demuestran que el agregado analizado cumple con los estándares establecidos. Además, la utilización del algoritmo yolo, en el análisis de los datos ha permitido reducir significativamente el tiempo de ejecución física y mejorar el estudio granulométrico de los agregados utilizados en la construcción de concreto. La combinación de estas herramientas tecnológicas ha demostrado ser una estrategia efectiva para mejorar el análisis granulométrico y optimizar los procesos de investigación. Se probó la hipótesis general ( $H_i$ ) que afirma la efectividad de las canteras, aceptando la hipótesis nula ( $H_0$ ).

## 7. Referencias

- Azizi, A.; Gilandeh, Y. A.; Mesri-Gundoshmian, T.; Saleh-Bigdeli, A. A.; Moghaddam, H. A. (2020). Classification of soil aggregates: A novel approach based on deep learning. *Soil and Tillage Research* v.199. <https://doi.org/10.1016/j.still.2020.104586>
- Barrios, Juan. (2019). La matriz de confusión y sus métricas Inteligencia Artificial.
- Benites, Luis. (2022). Error absoluto y error absoluto medio (MAE).
- Bisong, E. (2019). Google Colaboratory. [https://doi.org/10.1007/978-1-4842-4470-8\\_7](https://doi.org/10.1007/978-1-4842-4470-8_7)
- Brownlee, Jason. (2018). Utilice la detención anticipada para detener el entrenamiento de las redes neuronales en el momento adecuado.
- Capistran Olvera, O. I. (2020). Sistema de Aprendizaje Automático para Detección y Análisis de Tráfico Vehicular.

## ENGLISH VERSION

- Chávez, G. M.; Sarocchi, D.; Santana, E. A.; Borselli, L. (2015).** *Optical granulometric analysis of sedimentary deposits by color segmentation-based software: OPTGRAN-CS.* 85. *Computers & Geosciences, Volume 85, Part A, Pages 248-257.* <https://doi.org/10.1016/j.cageo.2015.09.007>
- De La Cruz Casano, C.; Catano Sanchez, M.; Rojas Chavez, F.; Vicente Ramos, W. (2020, October 21).** *Defect Detection on Andean Potatoes using Deep Learning and Adaptive Learning.* *IEEE Engineering International Research Conference (EIRCON), Lima, Peru, 2020, pp. 1-4, doi: 10.1109/EIRCON51178.2020.9254023.* <https://doi.org/10.1109/EIRCON51178.2020.9254023>
- Erazo, C.P.; Navarrete, G.A. (2022).** *Detección de pistas aéreas ilegales en imágenes digitales empleado técnicas de inteligencia artificial.* *Ciencia Y Poder Aéreo, 18(1).* <https://doi.org/10.18667/cienciaypoderaereo.758>
- Goodfellow, I.; Bengio, Y.; Courville, A. (2016).** *Redes Convolucionales.*
- Greyrat, Rudeus. (2022).** *Elija el número óptimo de épocas para entrenar una red neuronal en Keras.*
- Herrera Herbert, J. (2007).** *Diseño de Explotaciones de Cantera.* Universidad Politécnica de Madrid. Departamento de Explotación de Recursos Minerales y Obras Subterráneas, Madrid. <https://doi.org/10.20868/UPM.book.21839>.
- Kumar, Kodwani Hitesh; Asange, Sourabh. (2021).** *Influencia de agregados ing.en.es.*
- Madrigal, Esteban. (2022).** *Conoce las métricas de precisión más comunes para Modelos de Regresión.*
- Muñoz Gomez, S. A. (2019).** *Evaluación y calibración de software para la obtención de granulometría mediante análisis digital de imágenes.* Memoria de Título para optar al título de Ingeniero Civil de Minas. Concepción, Chile: Universidad de Concepción. 92p.
- NTP 350.001. (1970).** *Norma Técnica Peruana 350.001.* Lima, Perú: Comisión de Reglamentos Técnicos y Comerciales
- NTP 400.12. (2001).** *Norma Técnica Peruana 400.12.* Lima, Perú: Comisión de Reglamentos Técnicos y Comerciales
- Pérez, R. M.; Arias, J. S.; Porras, A. M. (2019).** *Introducción al Aprendizaje Automático con YOLO.* *Tecnología Vital. Vol. 2 Núm. 6.* <https://developer.nvidia.com/cuda->
- Pitarque, A.; Carlos Ruiz, J.; Roy, J. F. (1991).** *Las redes neuronales como herramientas estadísticas no paramétricas de clasificación.* *Psicothema, Vol. 12, (2), pp. 459-463.*
- Ribeiro, Lucas. (2020).** *Medición de granulometría de mineral de hierro mediante imágenes en circuito de trituración primaria.*
- Sampieri, R.; Collado, C.; Baptista P.; Casas, M. (1991).** *Metodología de la investigación.* México: McGraw-Hill.
- Soto Serrano, A. (2017).** *Detector de objetos YOLO para conducción a bordo Imágenes.*
- Sugue Javier, J. (2020).** *Análisis de algoritmos de detección de características de OpenCV en Raspberry Pi.*
- Universidad Central de Venezuela. (2013).** *El Conocimiento Científico y Tecnológico y en el Ámbito de la Ingeniería y Disciplinas Afines.*
- Verian, K.P.; Ashraf, W.; Cao, Y.; (2018).** *Properties of recycled concrete aggregate and their influence in new concrete production.* *Resources, Conservation and Recycling, Vol. 133, pp. 30–49.* <https://doi.org/10.1016/j.resconrec.2018.02.005>
- William, S. G. (2015).** *t-Student: Usos y abusos.* *Revista Mexicana de Cardiología, 26(1), 59–61.* [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S0188-21982015000100009&lng=es&nrm=iso&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-21982015000100009&lng=es&nrm=iso&tlng=es)