

**ANÁLISIS GRANULOMÉTRICO DE LA GRAVA PARA FABRICACION DE
CONCRETO HIDRÁULICO MEDIANTE PROCESAMIENTO DIGITAL DE
IMÁGENES Y TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**



**DANIEL AUGUSTO MUÑOZ VIVEROS
JUAN DAVID MUÑOZ VELASCO**

Director

Gustavo Adolfo Ramírez González

Codirector

Cristhian Nicolás Figueroa Martínez

Universidad del Cauca
Facultad de Ingeniería Electrónica y Telecomunicaciones
Departamento de Telemática
Popayán, 2022

DANIEL AUGUSTO MUÑOZ VIVEROS
JUAN DAVID MUÑOZ VELASCO

ANÁLISIS GRANULOMÉTRICO DE LA GRAVA PARA FABRICACION DE
CONCRETO HIDRÁULICO MEDIANTE PROCESAMIENTO DIGITAL DE
IMÁGENES Y TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Trabajo de grado presentado a la Facultad de Ingeniería
Electrónica y Telecomunicaciones de la
Universidad del Cauca como requisito para optar al
Título de

Ingeniero en Electrónica y Telecomunicaciones

Director
Gustavo Adolfo Ramírez González

Codirector
Cristhian Nicolás Figueroa Martínez

Popayán, 2022

AGRADECIMIENTOS

Principalmente a Dios, por ser el guía de mi vida y permitirme llegar hasta el punto donde me encuentro hoy. A mi padre, por ser parte esencial en este proyecto gracias por su conocimiento y apoyo. A mi madre por su amor y apoyo incondicional durante esta etapa y toda mi vida. A mi familia por siempre querer lo mejor para mí y ayudarme cuando lo necesito. A mi esposa, por ser un modelo a seguir e impulsarme a sacar este proyecto adelante. A JD, no pude tener un mejor compañero de tesis, supimos entender y comprender los tiempos de cada uno para poder terminar este proyecto. A todas y cada una de las personas con las que compartí en esta etapa, porque su aporte fue indispensable para poder llegar hasta aquí.

Antes que nada, agradezco a Dios por rodearme de personas tan buenas a lo largo de este camino. A mis padres, ejemplo de perseverancia, desde el primer momento, con amor, me guiaron y brindaron su apoyo incondicional. A mi familia, quienes me dieron su sostén y ayuda en todo momento. A Camila y su familia, que siempre con paciencia y amor estuvieron a mi lado acompañándome. A mis amigos por su infinito acompañamiento y tolerancia. A Eva que estuvo con firmeza y lealtad a mi lado en los días más largos. A mi compañero Daniel por el liderazgo, empeño y soporte a lo largo de la realización de esta investigación.

Finalmente, agradecemos a nuestros directores por su paciencia y constancia en este trabajo, por brindar su tiempo para dirigir este proyecto. Fueron parte importante de este logro con sus múltiples aportes, confianza y acompañamiento incondicional.

Resumen estructurado

Antecedentes: el análisis granulométrico destaca en diferentes campos de investigación y aplicación industrial en sectores como el farmacéutico, el alimentario, en la producción de materias primas para la construcción, entre otros. En el campo de la geotecnia, el análisis granulométrico es fundamental para evaluar la distribución de tamaños de un material según una serie de normas establecidas, y determinar en qué tipo de estructuras es posible utilizar dicho material. Actualmente el método más utilizado para la estimación del análisis granulométrico consiste en la segmentación mecánica de las partículas, este proceso consiste en verter una muestra representativa de las partículas en una serie de tamices vibratorios, donde un operario registra el peso de las partículas retenidas y las partículas que pasan por cada tamiz. Estos datos registrados son procesados para poder conocer la distribución de tamaño total de la muestra. En consecuencia, la aplicación y el desarrollo de nuevas tecnologías o el refuerzo de las herramientas existentes que permitan la reducción del tiempo de ejecución, manteniendo niveles de precisión similares a los de la granulometría por tamizado, y la reducción de los costes de ejecución, son necesarios para conseguir un procedimiento más eficiente.

Objetivo: estimar la composición granulométrica de la grava para la fabricación de concreto hidráulico mediante el procesamiento digital de imágenes basado en técnicas de aprendizaje automático, teniendo en cuenta el tiempo de ejecución del proceso y su nivel de precisión.

Métodos: se propuso obtener la distribución de tamaños de un material para construcción de una forma alternativa a la granulometría tradicional por tamizado, buscando reducir el tiempo de ejecución. Mediante un prototipo hardware, capturar una imagen de dicho material (que fue facilitado por un geotecnólogo experto en el área), para ser segmentada mediante procesamiento digital de imágenes, y obtener datos de las partículas que lo componen. Luego con los datos obtenidos, implementar algoritmos de aprendizaje automático de modo que clasifiquen esas partículas y predigan su peso, a fin de alcanzar resultados con una precisión aproximada a los resultados de una granulometría tradicional, en un tiempo menor.

Resultados: el trabajo de grado generó un conjunto de datos que contiene características de cada partícula de la grava. Un prototipo hardware que facilita la captura de la imagen del material para su posterior segmentación, reconocimiento de partículas y obtención de datos con ayuda de un modelo software creado para dicha tarea. Un conjunto de modelos que clasifican las partículas y estiman su peso. Finalmente, un sistema (unificando lo anterior) para adquirir la distribución de tamaños de las partículas, donde en la clasificación, la métrica de evaluación fue *exactitud* con un resultado de 91.02%; y para la predicción del peso, la métrica de evaluación fue “*RMSE*” con un resultado de 1.4685. Adicionalmente, el sistema disminuye el tiempo de ejecución en un 75%, comparado con la granulometría tradicional.

Palabras Clave: aprendizaje supervisado, concreto hidráulico, granulometría, procesamiento digital de imágenes.

Structured abstract

Background: the granulometric analysis stands out in different fields of research and industrial application in sectors such as pharmaceuticals, food, in the production of raw materials for construction, among others. In geotechnics, the granulometric analysis is a fundamental process to evaluate the distribution of a material according to a series of established standards, and to determine the type of possible structures where such material is suitable. Currently the most used method for the estimation of the granulometric analysis consists of the mechanical segmentation of particles, this process consists of pouring a representative sample of the particles in a series of vibrating sieves, where an operator registers the weight of the particles that pass and those that are retained in each sieve. The data obtained are processed so the total size distribution of the sample can be known. Consequently, the application and development of new technologies or the reinforcement of existing tools that allow the reduction of the execution time, maintaining levels of precision to the sieving granulometry and reduction of the execution costs, are necessary to achieve a more efficient procedure.

Objective: to estimate the granulometric composition of gravel for the manufacture of hydraulic concrete through digital image processing based on machine learning techniques, taking into account the implementation time of the process and its level of precision.

Materials and methods: an alternative way to get the size distribution of a construction material, seeking to reduce the execution time. By means of hardware prototype that helps to capture an image of the material, to be segmented by digital image processing, and to get particles data that integrate it, to implement machine learning algorithms to classify these particles and predict their weight, in order to achieve results with an approximate accuracy to the results of a traditional granulometry, in less time.

Results: a dataset that contains features of each gravel's particle. A hardware prototype that helps material image capture for segmentation, particle recognition and data acquisition using a software model created for this task. A set of models that classify the particles and estimate their weight. Finally, a system that joins all of the above to obtain the size distribution of the particles.

Keywords: supervised learning, hydraulic concrete, granulometry, Digital image processing.

Contenido

Lista de figuras	14
Lista de tablas	16
1. Introducción	17
1.1. Planteamiento del problema.....	17
1.2. Objetivos	19
1.2.1. Objetivo general.....	19
1.2.2. Objetivos específicos.....	19
1.3. Partes de la memoria	19
2. Estado actual del conocimiento	22
2.1. Conceptos y definiciones fundamentales	22
2.1.1. Análisis granulométrico.....	22
2.1.2. Concreto hidráulico.....	23
2.1.3. Clasificación.....	23
2.1.4. Segmentación.....	23
2.1.5. Aprendizaje supervisado	23
2.1.6. Visión por computadora.....	24
2.1.7. Árboles de decisión (<i>Decision Tree</i>).....	24
2.1.8. Bosques aleatorios (<i>Random Forest</i>)	24
2.1.9. Bagging	25
2.1.10. Máquina de vectores de soporte (<i>SVM</i>).....	25
2.1.11. Boosting	25
2.1.12. K- Vecinos más cercanos (kNN)	25
2.1.13. Regresión lineal.....	26
2.1.14. Regresión Ridge.....	26
2.2. Trabajos relacionados	26
2.2.1. Estudios realizados en Latinoamérica	28
2.2.2. Estudios realizados en otros países	30
2.3. Brechas existentes	32
2.4. Aportes del proyecto	34
3. Materiales y métodos.....	36

3.1. Modulo Hardware	36
3.2. Modulo software	44
3.2.1. Modulo para la segmentación de imágenes y captura de datos	45
3.2.1.1. Creación del conjunto de datos	45
3.2.1.2. Análisis exploratorio de los datos (<i>EDA</i>)	49
3.2.2. Módulo para la clasificación de cada partícula y estimación de su peso. 57	
3.2.2.1. Modelo de clasificación	58
3.2.2.2. Modelo de regresión.....	64
4. Resultados.....	71
4.1. Ejecución de la prueba.....	71
4.2. Discusión.....	75
5. Conclusiones y trabajos futuros.....	79
5.1. Conclusiones.....	79
5.2. Trabajo futuros	80
6. Bibliografía.....	82
A Código fuente.....	90
B Montaje prototipo y ejecución del software	90
C Manual de instrucciones	90
D. Estimación grado de desarrollo de la tecnología (trl)	95

Lista de figuras

Figura 1. Diagrama estratégico de temas relacionados. Fuente propia.	28
Figura 2. Diseño sistema propuesto. Fuente propia.	36
Figura 3. Iluminación esférica. Fuente propia.....	37
Figura 4. Iluminación posterior difusa. Fuente propia.....	38
Figura 5. Iluminación esférica prueba uno. Fuente propia.....	39
Figura 6. Iluminación esférica prueba dos. Fuente propia.	39
Figura 7. Iluminación posterior difusa prueba uno. Fuente propia.....	40
Figura 8. Iluminación posterior difusa prueba dos. Fuente propia.	40
Figura 9. Base luminosa para el modulo hardware del sistema propuesto. Fuente propia.	41
Figura 10. Base de soporte para el modulo hardware del sistema propuesto. Fuente propia.	42
Figura 11. Modulo fotográfico del sistema propuesto. Fuente propia.	43
Figura 12. Prototipo final del sistema para visión artificial. Fuente propia.	44
Figura 13. Fases propuestas por el modelo CRISP-DM. Adaptado de [38].	45
Figura 14. Imagen material para conjunto de entrenamiento. Fuente propia.	47
Figura 15. Imagen material para conjunto de entrenamiento sin contorno negro. Fuente propia.	47
Figura 16. Resultado de implementación de filtro Canny (detección de contornos). Fuente propia.	48
Figura 17. Captura de datos a partir de las características de cada partícula. Fuente propia.	49
Figura 18. Ejemplo de algunas instancias del conjunto de datos construido. Fuente propia.	49
Figura 19. Información del conjunto de datos. Fuente propia.....	51
Figura 20. Gráficos de caja e histogramas para variables de tipo numérico. Fuente propia.	52
Figura 21. Gráficos de barras para variables categóricas. Fuente propia.	53
Figura 22. Gráficos de dispersión variables independientes vs Peso. Fuente propia.	55
Figura 23. Etapas que conforman la fase de modelado. Adaptado de [38].	57
Figura 24. Representación del primer enfoque. Fuente propia.....	58
Figura 25. Representación del segundo enfoque (validación cruzada). Fuente propia.	58
Figura 26. Técnica de validación cruzada: Grid Search. Fuente propia.	62
Figura 27. Gráfica de errores. Fuente propia.....	66
Figura 28. Histograma para representación de la distribución de los errores. Fuente propia.	66
Figura 29. Mapa de calor de la correlación de Spearman entre variables independientes. Fuente propia.....	67
Figura 30. Diagrama de funcionamiento del sistema propuesto. Fuente propia... 72	

Figura 31. Imagen del nuevo material. Fuente propia.	73
Figura 32. Gráfica granulometría del sistema nuevo propuesto. Fuente propia. ..	74
Figura 33. Gráfica granulometría tradicional realizada por el experto. Fuente propia.	75
Figura 34. Comparación curva granulométrica tradicional vs Sistema propuesto. Fuente propia.	77

Lista de tablas

Tabla 1. Resumen comparativo de trabajos relacionados. Fuente propia.	32
Tabla 2. Identificación de variables del conjunto de datos. Fuente propia.....	50
Tabla 3. Resultados del test de Kruskal- Wallis con la variable Tamiz. Fuente propia.	54
Tabla 4. Resultados del test de correlación de Spearman con la variable Peso. Fuente propia.	56
Tabla 5. Resultados del test de Kruskal- Wallis con la variable Peso. Fuente propia.	57
Tabla 6. Porcentaje de exactitud de los algoritmos de clasificación para el primer enfoque. Fuente propia.	60
Tabla 7. Porcentaje de exactitud de los algoritmos de clasificación para validación cruzada. Fuente propia.	60
Tabla 8. Porcentaje de exactitud de los algoritmos de clasificación para grid_search. Fuente propia.	62
Tabla 9. Resultados de RMSE de regresión lineal y Ridge. Fuente propia.	68
Tabla 10 Resultados RMSE de los algoritmos de regresión para el primer enfoque. Fuente propia.	68
Tabla 11. Resultados RMSE de los algoritmos de regresión para el segundo enfoque. Fuente propia.	69
Tabla 12. Resultados RMSE de los algoritmos de regresión para Grid Search. Fuente propia.	70
Tabla 13. Resultados granulometría por el sistema propuesto del nuevo material. Fuente propia	73
Tabla 14. Resultados granulometría tradicional del nuevo material. Fuente propia.	75
Tabla 15. Comparación clasificación de partículas Granulometría Tradicional vs Sistema propuesto. Fuente propia.	76
Tabla 16. Comparación peso retenido Granulometría Tradicional vs Sistema propuesto. Fuente propia.	77

1. Introducción

1.1. Planteamiento del problema

El análisis granulométrico es uno de los procesos con mayor importancia para la ingeniería civil debido a que establece la base analítica de estructuración y caracterización de una construcción. Gracias a la granulometría es posible obtener la escalabilidad de una base granular, la verificación del tamaño de las partículas de un agregado para la preparación de un concreto hidráulico, o conocer la distribución de tamaños de partículas en un filtro que son situaciones que constantemente se presentan en cualquier tipo de obra civil[1].

En las construcciones, una incorrecta distribución de los materiales provocaría fallas en el dominio físico del producto final, una serie de riesgos económicos y deficiencias ambientales para las empresas productoras [2]. En adición, la distribución de tamaños de un material debe ser evaluado por una serie de normas establecidas [3], por ejemplo, en Colombia la entidad encargada de definir esas normas es el INVIAS, con el fin de determinar en qué tipo de construcción es posible usar dicho material.

Actualmente el método más utilizado para la estimación del análisis granulométrico consiste en la segmentación mecánica de partículas, tal como lo describen Ferrari, Piuri y Scotti [4]. Este proceso consiste en verter una muestra representativa de las partículas de interés en una serie de tamices vibratorios, donde un operario se encarga de registrar el ponderado de partículas retenidas y de partículas pasantes por cada tamiz. A continuación, esos datos registrados son procesados de tal manera que se pueda conocer la distribución de tamaños promedio de la muestra. Este método presenta inconsistencias dado que lleva consigo el error sistemático resultante de la idoneidad con la que el operario realice este proceso, es decir, una muestra puede ser analizada por múltiples operarios expertos y diferir en los resultados, y aunque su precisión se acerca a los límites de estandarización, está sujeto a las capacidades del operario y la correcta ejecución de los procedimientos [5].

Como mencionan Ferrari, Piuri y Scotti en una de sus investigaciones [6], la granulometría por tamizado es realizada por expertos humanos sobre una muestra representativa del material a examinar, lo que hace que este proceso sea bastante lento para obtener un análisis. La realización de este proceso toma entre 12 y 24 horas de trabajo, pudiéndose presentar retrasos debido a que en la mayoría de empresas de construcción y obras civiles no se cuenta con un laboratorio apropiado. En esos casos se hace necesario, transportar la muestra hasta un laboratorio certificado, incrementando tanto tiempo como costos. De esta forma es posible definirlo como un proceso poco eficiente y de baja productividad, con respecto a la toma de decisiones relevantes en un entorno práctico laboral, tales como la conveniencia de usar o no, ese material en construcciones específicas. Por lo tanto, surge la necesidad de generar un análisis granulométrico rápido y en algunos casos de manera inmediata.

En este sentido, es evidente la necesidad de aplicar un esfuerzo continuo en investigación y desarrollo de nuevas tecnologías o en la mejora de herramientas ya existentes que permitan la reducción de tiempos de ejecución, manteniendo estables los niveles de precisión comparados a la granulometría por tamizado y sin provocar un aumento en los costos de ejecución, logrando así, obtener la mayor eficiencia del mismo.

En este orden de ideas, la adopción de las tecnologías de la información y computación en conjunto con el aprendizaje automático, actualmente brinda mejoras importantes en la optimización de diferentes procesos. Algunos enfoques innovadores [4], [7]–[11], proponen el aprovechamiento de tecnologías basadas en visión por computadora para generar una estimación de lo que sería un análisis granulométrico en condiciones controladas de laboratorio. De esta forma minimizar la intervención humana y disminuir dicho tiempo de realización del proceso, ya que directamente desde una imagen, es posible obtener tanto la distribución de tamaños como la clasificación con base a la forma de las partículas, otorgando a los sistemas la capacidad de trabajar no solo con una muestra sino directamente en línea de producción.

Algunos autores como Bianconni, Di María y Micale [12], Araujo, Pessota y Kim [11], proponen que las imágenes sean tomadas de tal forma que la cámara esté ubicada por encima del material. Por otro lado, están aquellos autores como Ferrari, Piuri y Scotti [4], que proponen que sean tomadas mientras el material se encuentra en caída libre, dado que soluciona el problema de individualización. No obstante, desprende un nuevo problema a nivel de captura de imágenes, dado que es necesario minimizar el tiempo de exposición en la toma de fotografías para lograr enfocar el material, elevando el grado de complejidad del sistema de imágenes e incrementando costos por la adquisición de cámaras especializadas.

Por otro lado, los enfoques suelen estar divididos en dos grupos, aquellos encargados de segmentar cada una de las partículas dentro de una imagen digital [13], [14], y otro grupo que se encarga de clasificar cada partícula segmentada con el fin de generar un análisis granulométrico [4], [11], [22], [12], [15]–[21].

En consecuencia, la presente investigación desarrolló un prototipo hardware que utiliza iluminación posterior difusa, para capturar las imágenes del material de una forma óptima, de manera que la cámara esté ubicada encima del material para un mejor reconocimiento del mismo. A su vez se integró un módulo que implementó técnicas como el filtro de escala de grises, el filtro gaussiano y el filtro *canny*, que están basados en el procesamiento digital de imágenes, para segmentar dicha imagen y obtener datos de las partículas que componen el material; además, también se implementaron bosques aleatorios como algoritmo de aprendizaje automático, con el cual se obtuvo los mejores resultados tanto para clasificar las partículas según el tamiz que las retenía, como para predecir el peso de cada una de ellas en las métricas utilizadas para cada proceso (exactitud y “RMSE” respectivamente), con el fin de obtener el análisis

granulométrico en el menor tiempo posible y manteniendo su nivel de precisión con respecto a la curva granulométrica obtenida al final, tanto en el sistema propuesto como en la granulometría tradicional.

El concreto hidráulico es el material con mayor cantidad de usos y aplicaciones civiles a partir de la puesta en funcionamiento de un prototipo fabricado para llevar a cabo este proceso, por dicha razón es el material escogido en esta investigación. En este sentido, se plantea la siguiente pregunta de investigación:

¿Cómo disminuir el tiempo de análisis de procesamiento de la granulometría por tamizado empleando técnicas de procesamiento de imágenes y aprendizaje automático en la grava utilizada para la creación de concreto hidráulico manteniendo el nivel de precisión?

1.2. Objetivos

A continuación, se expone el objetivo general de la presente investigación, así como los objetivos específicos mediante los que se aborda la solución de la problemática formulada en la sección 1.1.

1.2.1. Objetivo general

Estimar la composición granulométrica de la grava para la fabricación de concreto hidráulico mediante el procesamiento digital de imágenes basado en técnicas de aprendizaje automático, teniendo en cuenta el tiempo de ejecución del proceso y su nivel de precisión.

1.2.2. Objetivos específicos

- Evaluar técnicas de aprendizaje automático que permitan procesar y analizar imágenes capturadas por el módulo fotográfico del prototipo, con respecto a un análisis granulométrico obtenido en condiciones controladas de laboratorio.
- Construir un prototipo hardware con las técnicas de mejor desempeño que facilite la captura y procesamiento de imágenes para realizar el análisis granulométrico utilizando un ordenador de placa única.
- Evaluar el proceso de granulometría óptica diseñado, comparando el tiempo y nivel de precisión, respecto al proceso de granulometría por tamizado.

1.3. Partes de la memoria

La presente monografía se encuentra dividida en los siguientes cinco capítulos que conforman la investigación realizada:

- **Capítulo 1:** presenta la introducción, el planteamiento del problema de investigación y la estructura general del trabajo realizado.
- **Capítulo 2:** denominado “Estado actual del conocimiento”, hace referencia a las tecnologías y conceptos en los que se fundamenta la presente investigación, además de las experiencias previas llevadas a cabo en otras investigaciones de aprendizaje automático con enfoque en visión por computadora y granulometría que se relacionan con la expuesta en el presente trabajo.
- **Capítulo 3:** denominado “Materiales y métodos”, describe todo el proceso de construcción y evaluación del prototipo hardware que permita capturar las imágenes del material de estudio, elaboración del conjunto de datos comprendiendo la adquisición, selección, estructuración, verificación, limpieza e integración de los datos y finalmente, el entrenamiento de los modelos de aprendizaje automático para la correcta estimación granulométrica.
- **Capítulo 4:** denominado “Resultados”, presenta la síntesis de los resultados de la presente investigación mediante los diferentes escenarios de prueba, describe de manera general el funcionamiento del prototipo desarrollado, así como una comparación entre los resultados de una granulometría por tamizado y los resultados obtenidos con el sistema propuesto.
- **Capítulo 5:** denominado “Conclusiones y trabajos futuros”, se exponen las conclusiones obtenidas en el desarrollo del trabajo de grado, y elementos a tener en cuenta en el desarrollo de trabajos futuros e investigaciones en este campo.

2. Estado actual del conocimiento

En este capítulo se recopilan los conceptos y tecnologías en que se fundamenta esta investigación. De igual forma, se describen aquellas investigaciones recientes y/o representativas que se han desarrollado en torno a la implementación de aprendizaje automático en el campo de la geotecnia, más precisamente en el análisis granulométrico.

El capítulo se encuentra dividido en las siguientes secciones:

- **Conceptos y definiciones fundamentales:** se definen las bases teóricas de la investigación, exponiendo a detalle los conceptos que toman relevancia en los resultados obtenidos.
- **Trabajos relacionados:** presenta la exploración del estado actual del conocimiento llevada a cabo con el objetivo de determinar las investigaciones relacionadas con la presente, adicionalmente, se llevó a cabo un análisis bibliométrico sobre la producción científica alrededor del aprendizaje automático, con el fin de obtener una visión general de los desarrollos generados durante la última década en esta área y mostrar tendencias que podrían ser la base para la presente investigación y futuros desarrollos en este campo.

2.1. Conceptos y definiciones fundamentales

2.1.1. Análisis granulométrico

Existen diferentes sistemas de clasificación de las partículas individuales que componen el suelo, así como diferentes métodos para su determinación. Uno de ellos es la distribución de tamaño de partículas, la cual se refiere a la distribución porcentual de los tamaños de partículas presentes en el suelo, también conocida como la granulometría.

Al proceso de clasificar estas partículas se le conoce como análisis granulométrico y consiste en dividir y separar el material mediante una serie de tamices organizados de forma decreciente con diferentes aberturas que van desde los 125 mm hasta 0,075 mm. Se define tamiz como aquel utensilio que se emplea para la separación de materiales de diferente grosor ya que cuenta con una serie de aperturas en su interior permitiendo el paso o la retención de material. Posteriormente, desensamblar la serie de tamices, de tal manera que se pueda evaluar el peso retenido en cada uno para calcular su porcentaje pasante con respecto al peso total de la muestra. Finalmente, con los porcentajes pasantes en cada tamiz, obtener una curva granulométrica que permita visualizar la tendencia homogénea o heterogénea en la cual está distribuido el material[2].

2.1.2. Concreto hidráulico

El concreto es una mezcla homogénea de agua, arena, cemento, piedra y aditivos. Es un material resistente, durable y ya que se trabaja en forma líquida, puede adquirir cualquier tipo de forma. El concreto es un material creado por el hombre, diseñado y producido de acuerdo con normas establecidas para fines y aplicaciones en determinada construcción [3].

2.1.3. Clasificación

La clasificación comprende el proceso de reconocimiento, comprensión y agrupación de objetos en categorías preestablecidas. Los algoritmos de clasificación utilizados en el aprendizaje automático utilizan datos de entrenamiento con el fin de que próximos datos entren en una de las categorías predeterminadas. Con la ayuda de estos conjuntos de datos, la clasificación aprovecha una amplia gama de algoritmos para ordenar futuros conjuntos de datos en categorías respectivas y relevantes [23].

2.1.4. Segmentación

La segmentación de imágenes es el proceso de dividir una imagen en partes o regiones. Su objetivo es reducir la información para facilitar el análisis y comprensión de la imagen; separar una imagen entera en varias partes que son más significativas y más fáciles de procesar. La segmentación también puede depender de las distintas características que contenga la imagen, como el color o textura [24].

2.1.5. Aprendizaje supervisado

Nace en el contexto del aprendizaje automático y convive junto al aprendizaje no supervisado, los cuales pueden ser definidos brevemente como los métodos de computación que utilizan la experiencia para realizar mejores predicciones. El aprendizaje supervisado usa datos etiquetados con el fin de hacer una predicción que razone con el entorno, a partir de la aplicación de un modelo matemático sobre los datos. Para esto es necesario realizar dos etapas sobre los datos, una de entrenamiento y otra de sondeo [25].

La etapa de entrenamiento se utiliza generalmente para calibrar el modelo aplicado, mediante la examinación de las variables dependientes denominadas clase, y las variables independientes conocidas como atributos. Los resultados obtenidos en la etapa de entrenamiento pueden tomar valores continuos o discretos, para los primeros, los resultados se conocen como regresión y para los segundos, clasificación [26]. Posteriormente, a partir de los resultados obtenidos de la muestra de

entrenamiento, se realizan predicciones sobre una muestra de prueba para verificar la precisión de los resultados obtenidos en comparación con los datos de entrenamiento. En ocasiones también se pueden utilizar datos de validación los cuales generalmente no forman parte del mismo conjunto de datos con el cual fueron entrenados los algoritmos, con el fin de determinar con mayor objetividad los resultados. El objetivo al implementar aprendizaje supervisado es predecir en la muestra de prueba los patrones o comportamientos que se hayan identificado en la etapa de entrenamiento.

2.1.6. Visión por computadora

La visión por computadora es un campo de las ciencias de la computación enfocado en la aplicación de métodos para la adquisición, procesamiento y análisis de imágenes obtenidas del mundo real con el fin de producir información capaz de ser entendida por una máquina, intentando replicar el sistema de visión humana [27]. El uso de técnicas de aprendizaje automático tiene como objetivo conseguir diferenciar automáticamente patrones usando algoritmos matemáticos. Estas técnicas son comúnmente usadas para clasificar imágenes, para tomar decisiones o generar proyecciones de acuerdo a lo que se esté analizando.

2.1.7. Árboles de decisión (*Decision Tree*)

Los árboles de decisión son una forma de dividir recursivamente datos en estructuras secuenciales y jerárquicas, cuyos nodos internos o de decisión pueden tomarse como pruebas sobre patrones conocidos a partir de datos de entrada y cuyos nodos de hoja indican el valor de la clase o atributo, el cual puede definirse como las categorías sobre esos patrones. Estas pruebas se filtran a través del árbol para obtener una salida que razone de acuerdo al patrón de entrada. Los algoritmos de árboles de decisión pueden aplicarse y utilizarse en diferentes campos. Puede utilizarse como sustituto de los procedimientos estadísticos para encontrar datos, extraer texto, mejorar los motores de búsqueda y también diversas aplicaciones en diferentes campos de la medicina [28].

2.1.8. Bosques aleatorios (*Random Forest*)

Los bosques aleatorios corresponden a una técnica de regresión que combina el rendimiento de numerosos algoritmos de aprendizaje automático con el fin de clasificar o predecir el valor de una variable. Para ello, esta técnica necesita recibir una muestra de entrada, formada por los valores de las diferentes características probatorias analizadas para un área de entrenamiento determinada, posteriormente construye un número K de árboles de regresión y promedia los resultados. Para evitar la correlación de los diferentes árboles, la técnica de bosques aleatorios aumenta la diversidad de los árboles haciéndolos crecer a partir de diferentes subconjuntos de

datos de entrenamiento creados mediante un procedimiento denominado "*bagging*" [29].

2.1.9. Bagging

El *bagging* es una técnica utilizada para la creación de datos de entrenamiento mediante el re-muestreo aleatorio del conjunto de datos original con reemplazo, es decir, sin eliminar los datos seleccionados de la muestra de entrada para generar el siguiente subconjunto de esta forma se generan vectores aleatorios independientes con la misma distribución. Por lo tanto, algunos datos pueden utilizarse más de una vez en el entrenamiento, mientras que otros podrían no utilizarse nunca. Así, se consigue una mayor estabilidad de los datos de entrada y, al mismo tiempo, una mayor robustez frente a datos de entrada aumentando la precisión de la predicción [29].

2.1.10. Máquina de vectores de soporte (SVM)

La técnica de SVM es un método perteneciente al aprendizaje supervisado para realizar la clasificación dicotómica de vectores de características multidimensionales Originalmente, se desarrolló como un método de clasificación lineal, pero se encaminó hacia un clasificador no lineal y, por último, se extendió hacia la resolución de los problemas de regresión [30]. La idea básica del método SVM es transformar las características de entrada en un espacio de mayor dimensión en el que las dos clases pueden separarse linealmente mediante una superficie de alta dimensión, conocida como hiperplano. Dado un conjunto de datos de entrenamiento con N muestras, con un vector de L características de entrada, y sus correspondientes características de salida conocidas V.

2.1.11. Boosting

La acción de refuerzo o *boosting*, tienen como objetivo ayudar regularmente a los algoritmos de aprendizaje automático supervisado para aumentar la veracidad de la predicción o clasificación. Para lograr su objetivo, los algoritmos de *boosting* organizan de manera secuencial cada uno de sus modelos, de esta forma aprovecha la dependencia entre ellos aumentando el rendimiento ya que hace que un modelo posterior les dé más importancia a los errores cometidos por un modelo simple previo. Las predicciones generadas por cada modelo se combinan por medio de una votación para problemas de clasificación o mediante una suma ponderada para producir la predicción final en problemas de regresión [31].

2.1.12. K- Vecinos más cercanos (kNN)

El algoritmo de K Vecinos más cercanos o *K-Nearest Neighbor* por sus siglas en inglés (KNN) es un algoritmo encargado de almacenar todos los casos

disponibles y clasificar las nuevas clases basándose en una medida de similitud (por ejemplo, el resultado de funciones de distancia). El algoritmo funciona de tal forma que clasifica un caso por medio de la clasificación que tengan sus vecinos, es decir, asignando el caso a la clase más común entre sus K vecinos más cercanos medido por una determinada función de distancia, Por ejemplo, si $K = 1$, el caso se asigna dependiendo de la clase de su vecino más cercano. Existen tres distancias utilizadas para las variables continuas: Euclidiana, Manhattan, Minkowsky [30].

2.1.13. Regresión lineal

La regresión lineal dentro del área del aprendizaje automático suele utilizarse para la previsión y la predicción, debido a que el análisis de regresión puede determinar las relaciones causales entre variables dependientes e independientes. Según los modelos de regresión, las variables independientes predicen las variables dependientes [32]. El análisis de regresión estima el valor de la variable dependiente "y" debido al rango de valores que toma la variable independiente "x". La regresión lineal define la dependencia de la variable de acuerdo a la influencia de sus contrapartes independientes.

2.1.14. Regresión Ridge

La regresión lineal es un método estadístico cuyo principal objetivo es modelar la relación entre una variable continua y una o más variables independientes mediante el ajuste de una ecuación lineal. Sin embargo, es muy común que se presenten predictores correlacionados debido a que el número de predictores es superior al número de observadores. Ahora bien, una forma de atenuar el impacto de estos problemas es utilizar estrategias de regularización tal y cómo lo hace la regresión Ridge, la cual penaliza la suma de los coeficientes elevados al cuadrado, esta penalización se conoce como L2 y tiene el efecto de reducir de forma proporcional el valor de todos los coeficientes del modelo sin que estos lleguen a cero. El grado de penalización está controlado por el parámetro λ . Cuando λ es igual a cero, la penalización es nula y el resultado es equivalente al de un modelo lineal por mínimos cuadrados ordinarios [32].

2.2. Trabajos relacionados

Con el fin de encontrar material de apoyo para la investigación se ejecutaron dos búsquedas bibliográficas. Para esto se planteó la cadena de búsqueda ((*imag** OR *partic**) AND (*granulometry*)), estructurada de tal forma que permita obtener todas las coincidencias posibles a los términos '*imag*' y '*partic*' con ayuda del símbolo '*'. Dicha cadena de búsqueda se utilizó en WOS y SCOPUS, arrojando 1331 y 1881 artículos respectivamente. Con un total de 3212 artículos, se decide

usar la herramienta SciMAT [33] para generar un mapa científico para determinar las temáticas idóneas de la investigación.

Para el análisis, SciMAT genera una representación espacial entre disciplinas, campos de estudio, especialidades y autores[34]. De esta forma presenta un análisis de coocurrencia de palabras proporcionando información sobre temas del campo de investigación específico y adicionalmente hace seguimiento a la evolución del campo de estudio en diferentes periodos de tiempo consecutivos.

Con el fin de identificar los temas de investigación que han sido determinantes en los trabajos realizados alrededor del aprendizaje automático, granulometría y análisis de imágenes durante la última década, se generó un análisis de diagramas estratégicos (ver Figura 1). Con ello, se destaca la evolución del uso de aprendizaje automático en temas relacionados con el procesamiento, clasificación e interpretación de imágenes en diferentes marcos de trabajo, aunque, actualmente se encuentra en auge dicha aplicación en el estudio y reconocimiento de partículas en otros campos de investigación como medicina, alimentos y nanomateriales. En contraste, la aplicación de inteligencia artificial en el campo de la construcción no ha sido un tema altamente desarrollado y no aparecen como eje central de las investigaciones publicadas actualmente. Lo mismo sucede con temas relacionados con el análisis de producto minero o estudio de agregados. Por último, destacan diversos temas que han sido básicos y transversales en gran parte de las investigaciones como el aprendizaje automático, la toma de medidas y reconocimiento de características morfológicas.

La Figura 1 muestra el diagrama estratégico generado por SciMAT acerca del desarrollo y auge de los temas relacionados con la investigación. El diagrama se divide en cuatro cuadrantes. En el cuadrante superior derecho se encuentran los temas más desarrollados y fundamentales para la construcción del campo científico [35] relacionados con conceptos aplicables en la investigación. En esta investigación el concepto, "*particle*" se encuentra con la mayor centralidad y densidad de acuerdo con los 152 artículos. En el cuadrante superior izquierdo se encuentran los temas que están muy bien desarrollados, pero poco relacionados con conceptos de la investigación; el único concepto para esta investigación es "*Building*" con 5 artículos. En el cuadrante inferior izquierdo están situados los temas poco desarrollados con poca relación con la investigación, como se observa, "*Matter*" es el peor situado con 11 artículos relacionados. Y, por último, en el cuadrante restante los temas bastante relacionados con la investigación, pero poco desarrollados, en este caso "*Methods*" con 19 artículos relacionados.




Figura 1. Diagrama estratégico de temas relacionados. Fuente propia.

Cabe resaltar que la búsqueda no obtuvo investigaciones realizadas en Colombia, sin embargo, encontró múltiples artículos de Latinoamérica. A continuación, se presenta la descripción de los trabajos más relevantes en el estudio del análisis granulométrico de muestras, mediante el uso de procesamiento de imágenes y técnicas de aprendizaje automático. Esta sección clasifica los trabajos relacionados según la ubicación geográfica y su campo de investigación. La ubicación determina la normativa a la que debe regirse cada análisis y saber si una muestra de estudio es apta o no, y el campo de investigación ayuda a determinar la selección de técnicas de acuerdo con el tipo de muestras de análisis.

2.2.1. Estudios realizados en Latinoamérica

- **Campo de investigación: Alimentos**

Araujo, Pessota y Kim [11] propusieron un sistema informático para realizar inspección visual de frijoles mediante el análisis granulométrico multiforme por medio del índice de correlación entre granos. Luego dotaron al sistema con la capacidad de individualizar cada grano para

extraer sus principales propiedades. La principal contribución de este trabajo está en su sistema de tres módulos: 1) Mapeo de color de píxeles, 2) Segmentación de los granos de frijol, 3) Clasificación de los granos de frijol, para individualizar los granos incluso cuando se encuentran superpuestos unos de los otros, con una exactitud del 99,97%. Por otro lado, el sistema de clasificación basado en algoritmos K-means y K-NN logró clasificar correctamente 29.956 granos de un total de 29.993 lo cual significa una precisión del 99,87%.

- **Campo de investigación: Geotecnia**

El trabajo de Moreno Chávez, G. et al. [13] propuso un nuevo sistema que permite medir la distribución de tamaños de partículas de depósitos de rocas con una amplia gama de tamaños de rocas, desde placas hasta bloques. Utilizó un dispositivo llamado Microsoft Kinect que, junto con una técnica de segmentación basada en conjuntos de niveles y análisis de Fourier, producen distribuciones con el mismo comportamiento que las producidas tradicionalmente. Analizaron siete áreas, donde el porcentaje mínimo de precisión fue del 85% a pesar de existir ciertas limitaciones. Primero, la excesiva iluminación del sol, segundo, problemas de resolución del dispositivo que limitaron el análisis de partículas menores a 4mm, tercero, limitación de análisis de rocas con un área más grande al campo visual del Kinect, y por último, la dificultad de analizar materiales con propiedades de reflexión difusa.

En otra investigación de Moreno Chávez, G., et al. [19] desarrollaron un software para la obtención de la distribución del tamaño de grano basado en el método de intersecciones de Rosiwal que consiste en contar las intersecciones entre rocas en las imágenes. Para esto utilizaron el método de segmentación de imágenes con base en los colores presentes en la imagen, centrado en el modelo de campo de medición cuadrático de Markov controlado por entropía. El software creado fue probado en 14 ambientes sedimentológicos diferentes y los resultados obtenidos fueron semejantes a los del procedimiento manual realizado por expertos, con excepción del tiempo de ejecución.

La investigación de Sarocchi, D., et al. [15], capturó imágenes de las paredes de un depósito de rocas desde una posición determinada. Para esto, utilizaron líneas horizontales paralelas para medir sus intersecciones con las rocas, y utilizando el método de Rosiwal obtuvieron la distribución granulométrica de varios depósitos. Además, compararon este método con el de conteo de puntos (análisis modal), que es ampliamente utilizado y ha sido ya comprobado, y el análisis granulométrico tradicional por tamizado.

2.2.2. Estudios realizados en otros países

- **Campo de investigación: Nano materiales**

El trabajo de Kim, H., et al. [16] propuso un enfoque nuevo usando correlaciones cruzadas concentros de diferentes formas y tamaños, con algoritmos basados en morfología matemática y detección de formas para calcular el tamaño, la forma y distribución de poros de silicio. Su enfoque fue utilizado en el análisis de imágenes de microscopía electrónica de barrido (SEM, *Scanning Electron Microscope*) y permitió contabilizar la cantidad de poros de silicio y clasificarlos circulares o cuadrados, según el área de cada poro.

- **Campo de investigación: Medicina**

Los autores Stoklasa, R., et al. [17] diseñaron un clasificador de células HEp-2, comúnmente utilizadas en la detección de enfermedades autoinmunes. Este clasificador puede reconocer seis tipos de células teniendo en cuenta siguientes descriptores de imágenes: características de Haralick, patrones locales binarios, transformación de entidad invariante de escala (SIFT, *Scale-Invariant Feature Transform*), descriptores de superficie y descriptores basados en granulometría, para reconocer 6 tipo de células. Además, muestran una introducción de su versión de clasificador de células basado en K-NN, logrando una precisión del 64% comparado con otro tipo de clasificadores.

- **Campo de investigación: Geotecnia**

En la investigación de Jutzeler, M., et al. [18] desarrollaron un método para calcular la distribución del tamaño de partículas de las rocas clásicas. Este método considera dos pasos principales, análisis de imágenes y técnica funcional estereológica. El análisis de imágenes procesa las fotografías seleccionar y calcular las características de las partículas (diámetro, y relación de rocas del mismo tipo). Y la técnica funcional estereológica, que realiza la conversión de diámetros bidimensionales en un conjunto de datos tridimensional utilizando la deconvolución de funciones de distribución. Los resultados de este método son semejantes a los resultados obtenidos por medio de una granulometría tradicional (tamizado).

En otra investigación, los autores Gueguen, Soille, y Pesaresi [14] propusieron un método para segmentar objetos multiescala superpuestos en una imagen. Para ello descompusieron la imagen mediante granulometría óptica obteniendo una representación espacial en escala discreta. A continuación, segmentaron la imagen

descompuesta para conseguir una proyección particionada del espacio extraído de la imagen, permitiendo describir la imagen en una serie de objetos individuales a múltiples escalas.

Por otro lado, Bianconi, Di María, Micale, Fernández y Harvey [12] propusieron una metodología alternativa para realizar granulometrías ópticas basadas en la morfología del área y el uso combinado de aperturas y cierres morfológicos propios del concreto hidráulico. La propuesta emplea el método de morfología de área bipolar y combinar la información derivada tanto de aperturas como de cierres para determinar la distribución de tamaño. Finalmente, evaluaron su metodología utilizando un conjunto de 13 clases de agregados tamizados manualmente. Los resultados obtenidos mostraron concordancia con los resultados del tamizado, ya que el método propuesto determinó correctamente el 92% de los casos.

En la investigación de Salehizadeh, M. y Sadeghi, M. T. [20] desarrollaron tres técnicas basadas en imágenes que estiman la distribución del tamaño de fragmentos de piedras. Luego, compararon el rendimiento de dichas técnicas en dos conjunto de imágenes, y aunque señalaron que la granulometría tiene resultados muy cualitativos, no pudieron determinar el número exacto de partículas, ya que un problema común de las técnicas que utilizaron, no logran contar partículas de un tamaño muy pequeño, pero pueden distinguir la distribución de los objetos en imágenes reales, además de la limitación de la cámara para capturar objetos con diferentes texturas, disparidad y superposición.

Por otra parte, Andriani, G. F., y Walsh, N. [21] presentaron una comparación para evaluar las curvas de precisión entre la técnica de tamizado y el análisis de imágenes. Dentro de los resultados encontraron que las dos curvas son bastantes similares, pero con el análisis de imágenes solo se miden bien los granos arena y limo grueso. Además, reconocieron que el análisis por tamizado solamente tiene en cuenta el porcentaje de peso, mientras que por análisis de imágenes considera el tamaño de las partículas por lo que concluyen que las dos curvas a pesar de ser similares no son comparables por cuestión del análisis de variable. También mencionan que la segmentación de las imágenes y la preparación de las muestras son las principales fuentes de error.

En su trabajo, Yidong Chen [36] extendió la técnica de clasificación en texturas de imágenes a escala de grises dado que permiten discriminar entre texturas con características visuales prominentes. Para esto utilizó 42 conjuntos de agregados caracterizados por granulometrías de apertura y por granulometrías de cierre. Este trabajo extrajo las características mediante la transformada de Karhunen-Loeve, y pudo evidenciar que el reconocimiento mejoró mediante el uso de granulometrías de apertura y cierre, arrojando una precisión superior al

99% en datos carentes de ruido. Adicionalmente, Yidong Chen investigó el efecto del ruido uniforme agregado aleatoriamente, especialmente la robustez del modelo cuando se introduce ruido con el fin de definir un conjunto de clasificadores sensibles al ruido.

Stefano Ferrari, Vincenzo Piuri y Fabio Scotti [4] presentaron un método para obtener la distribución del tamaño de partículas en una imagen sin necesidad de segmentarla. Además, este método evita el uso de iluminación o posicionamiento específicos de las imágenes. Para esto, utilizaron un conjunto de técnicas de análisis de espacio de escala y procesamiento de imágenes adecuadas para extraer características relevantes para el análisis de granulometría. Luego, emplearon este conjunto de características como entrada en un clasificador basado en redes neuronales para lograr la clasificación de cada píxel individual de acuerdo con la probabilidad de pertenecer a una clase específica de tamaño de partículas.

En su investigación, Buscombe, D. [22] desarrolló una técnica de aprendizaje automático para estimar el tamaño de partículas y su forma, a partir de imágenes fotográficas de depósitos de rocas. La técnica propuesta fue entrenada para estimar el diámetro del tamiz (utilizados en la granulometría tradicional) a partir de las características de imagen, sin necesidad de conocer la escala de un píxel. Con esto pudo estimar la forma y tamaño de las rocas utilizando un conjunto de datos con 409 imágenes con etiquetas asociadas. Finalmente, desarrolló tres modelos de clasificación de la forma de la roca y dos modelos para estimar su tamaño. En los resultados obtuvieron un 88.33% de precisión aproximada con respecto a la granulometría tradicional.

2.3. Brechas existentes

La Tabla 1 muestra la clasificación de los artículos seleccionados por ubicación (donde se realizó el trabajo), ya sea Latinoamérica o en otros países; campo de investigación, es decir, si la investigación fue o no realizada en el área de geotecnia; las técnicas aplicadas dentro de la inteligencia artificial y el procesamiento de imágenes, especificando su aplicación (segmentación o clasificación). Finalmente muestra qué trabajos desarrollaron un prototipo para obtener sus resultados.

Tabla 1. Resumen comparativo de trabajos relacionados. Fuente propia.

Artículo	Ubicación		Campo de Investigación		Técnica		Aplicación	Prototipo
	Latam	Otros	Geotecnia	Otros	I.A.	Otra		
[11]	X			Alimentos	<i>K-NN</i>		Clasificar	X

[13]	X		X			Conjunto de niveles, análisis de Fourier	Segmentar	
[15]	X		X			Intersección de Rosiwal	Clasificar	
[19]	X		X			Campos de medida Markovianos, intersección de Rosiwal	Segmentar, Clasificar	
[12]		X	X			Morfología de área bipolar	Clasificar	X
[4]		X	X		Red Neuronal		Clasificar	X
[14]		X	X			Regionalización de imágenes, proyección particionada	Segmentar	
[16]		X		Nano materiales		Correlación cruzada, morfología matemática	Clasificar	
[17]		X		Medicina	<i>K-NN</i>		Clasificar	
[18]		X	X			Técnica funcional estereología	Clasificar	
[36]		X	X			Clasificación con base a texturas, transformada de Karhunen-Loeve	Clasificar	
[21]		X	X			Watershed, granulometría y área limítrofe (algoritmos basados en imágenes)	Segmentar, Clasificar	
[20]		X	X			Procesamiento de imágenes	Segmentar, Clasificar	
[22]		X	X		SediNet		Segmentar, Clasificar	
Este trabajo	X		X		Aprendizaje Automático	Procesamiento de imágenes	Segmentar, Clasificar	X

A continuación, el presente trabajo describe las principales deducciones obtenidas de los trabajos relacionados, de acuerdo con Tabla 1:

- La mayoría de los trabajos tienen un solo enfoque de aplicación, ya sea para clasificar o segmentar agregados. Por lo tanto, este trabajo

emplea ambas aplicaciones para generar un análisis granulométrico con base en tecnologías ópticas, con un mayor nivel de precisión.

- En Latinoamérica solo se encontró un trabajo que utilizó técnicas de inteligencia artificial, pero a diferencia de nuestro trabajo, este no se realizó sobre el campo de la geotecnia.
- Una de las grandes debilidades del desarrollo de la granulometría óptica, es la escasez de prototipos hardware que permitan sentar las bases para una posible estandarización de este proceso. Solamente en algunos trabajos [11-13] los autores llevaron sus investigaciones hasta el desarrollo del sistema hardware. El presente trabajo emplea técnicas de inteligencia artificial para mejorar la precisión de los resultados obtenidos en el análisis de imágenes y presenta un prototipo hardware que brinda las mejores condiciones para la obtención de estas.

2.4. Aportes del proyecto

El presente trabajo de grado realiza los siguientes aportes en el desarrollo investigativo del procesamiento de imágenes, inteligencia artificial y el área de geotecnia:

- Prototipo hardware para capturar y analizar imágenes del concreto hidráulico mediante granulometría óptica.
- Un módulo software que combina los paradigmas de aprendizaje automático y procesamiento de imágenes para la mejor extracción y clasificación de características de una imagen.
- Participación en la COLCOM 2020 (*IEEE Colombian Conference on Communications and Computing 2020*) con una publicación en sesión de poster titulado “*Análisis Granulométrico de Partículas Basado en Técnicas de Procesamiento Digital de Imágenes y Aprendizaje Automático*”.
- Es el primer trabajo en Colombia que genera una solución para la toma de decisiones en obras civiles en el menor tiempo posible, con una base tecnológica que aplica diferentes técnicas de aprendizaje automático. Por tal razón se realizó una solicitud de patente por el grado de innovación del trabajo.

3. Materiales y métodos

3.1. Modulo Hardware

La presente sección expone el proceso de diseño e implementación de un prototipo de visión artificial que proporciona las condiciones óptimas (con respecto a la posición de la cámara, ubicación del material y el tipo de iluminación utilizada) para capturar las fotografías del material de muestra con el fin de ser analizadas posteriormente en el módulo software. Luego, especifica las funcionalidades y diseño del prototipo y se describe todos los pasos llevados a cabo para la calibración de sus componentes.

El diseño inicial es el que muestra la Figura 2, el cual se compone de 3 módulos:

- La base luminosa.
- La base de soporte de dispersión.
- La caja de aislamiento de luz y soporte de placa lógica.

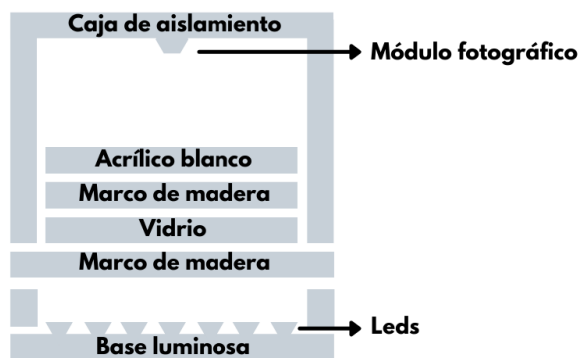


Figura 2. Diseño sistema propuesto. Fuente propia.

El primer módulo corresponde a la base luminosa. El segundo módulo corresponde a la base de soporte para la dispersión del material, y se compone de una placa de vidrio y una placa de acrílico contenidas en un marco de madera, ubicada sobre la cara superior de la base luminosa posibilitando el paso de la mayor cantidad de luz. Finalmente, el tercer módulo corresponde a la caja de aislamiento, que sostiene el modulo fotográfico y soporta el ordenador de placa única.

El punto de partida para el desarrollo del prototipo hardware fue un conjunto de muestras de piedras de concreto hidráulico y sus fotografías. Además, el desarrollo del prototipo comprendió el proceso de diseño y la elección de los dispositivos y mecanismos para la adquisición de imágenes adecuadas.

Un aspecto importante en el diseño del prototipo fue el mecanismo de iluminación de la escena, ya que el modo de iluminación es esencial para destacar todas las características de las piedras que se desea inspeccionar. Todo aquello resaltado en la captura de la imagen facilitó la selección y aplicación las técnicas de procesamiento de imágenes. Con base en la documentación encontrada [11], [12] el presente trabajo de grado aplicó la configuración luminosa esférica y la iluminación posterior difusa.

- **Iluminación esférica:** Al implementar este tipo de configuración, el objeto es iluminado desde todas las direcciones mediante una fuente de luz difusa tal cómo se puede evidenciar en la Figura 3. Esto posibilita la eliminación de sombras, reflejos y adicionalmente permite suavizar las texturas del objeto, minimizando la influencia de los relieves y curvaturas que pueda tener. Esta configuración luminosa es indicada para la detección de marcas en objetos con diferentes tipos de superficies.




Figura 3. Iluminación esférica. Fuente propia

- **Iluminación posterior difusa:** En este tipo de configuración lumínica, la fuente de iluminación va situada por debajo de la base del objeto a fotografiar. Idealmente la base sobre la que se encuentra el objeto debe ser translúcida (ver Figura 4), de manera que se produzca una sombra con la forma correspondiente al objeto, la cual, posteriormente es detectada por la cámara, obteniendo así el máximo contraste posible. Este tipo de iluminación es usada frecuentemente en la medición de perfiles de piezas y en la detección de impurezas en objetos transparentes o translúcidos.




Figura 4. Iluminación posterior difusa. Fuente propia

Las configuraciones lumínicas se pueden considerar como la parte crítica dentro de un sistema de visión artificial. Las cámaras fotográficas actuales tienen menor sensibilidad y versatilidad que la visión humana, por lo cual la condición luminosa debe optimizarse al máximo para que una cámara sea capaz de capturar aquellas características de una imagen que el ojo humano podría distinguir sin necesidad de una iluminación tan especializada. Lo anterior, se hace mucho más evidente cuando el objeto a iluminar presenta formas complejas, o superficies muy reflectantes [37].

En consecuencia, el presente trabajo describe la construcción un prototipo inicial, con base en el diseño de una caja luminosa, que ofrece un entorno cerrado evitando la influencia de luces exteriores, óptimo para la fotografía de productos. El prototipo puede ser modificado según el tipo de iluminación que se desee aplicar.

- Configuración de iluminación esférica:

Para la evaluación del sistema de iluminación se hicieron dos pruebas, la primera sin tener en cuenta la organización del agregado y otra individualizando cada partícula del material. Adicionalmente se aplicó el filtro *Canny*, el cual se basa en encontrar los bordes que existen en la imagen. Primeramente, detecta cambios de intensidad entre los objetivos de la imagen y su fondo, luego con esta detección poder filtrar los cambios de intensidad que son considerados bordes, y finalmente aplicar un umbral para reconocer un pixel como parte del borde o del fondo.

La Figura 5 muestra la imagen resultante después de aplicar el filtro *Canny*, en la cual se evidencia mucho ruido al interior de cada una de las partículas reconocidas por el sistema, además que no es posible identificar el número de partículas que se encuentran en la imagen. Lo anterior, se debe a que reconoce

aquellas pequeñas figuras formadas por la textura de cada partícula, imposibilitando la correcta segmentación de cada piedra.



Figura 5. Iluminación esférica prueba uno. Fuente propia.

Por otro lado, en el resultado de la prueba dos (ver Figura 6), se puede diferenciar el borde de cada partícula, pero se genera ruido al interior de cada piedra reconocida por el sistema.




Figura 6. Iluminación esférica prueba dos. Fuente propia.

- Configuración de iluminación posterior difusa:

Para evaluar el comportamiento del sistema implementando la configuración luminosa posterior difusa se emplearon las mismas pruebas, la primera sin tener en cuenta la organización del agregado y otra individualizando cada partícula del material. Tal y cómo se afirma en la definición, este tipo de iluminación es óptima cuando se requiere reconocer el borde del objeto a inspeccionar, dejando a un lado las características superficiales del objeto.

Como muestra la Figura 7 es posible confirmar la teoría, no obstante, al haber partículas sobrepuestas es posible observar que no existe una segmentación correcta después de aplicar el filtro *Canny*. Esto se debe, a que no hay una separación óptima entre partículas obstaculizando el proceso de reconocimiento y extracción de características que serán expuestas en la sección 3.2.1.2.



Figura 7. Iluminación posterior difusa prueba uno. Fuente propia.

La Figura 8 muestra los resultados obtenidos aplicando iluminación posterior difusa y asignando un espacio individual a cada partícula, para lograr una segmentación adecuada.



Figura 8. Iluminación posterior difusa prueba dos. Fuente propia.

Cómo conclusión de esta primera fase del desarrollo se deduce que existen inconvenientes relacionados con la tarea de segmentación, debido al tipo de iluminación empleada y el posicionamiento de las partículas, tal y cómo lo describen los autores Ferrari, Piuri, y Scotti en [4]. Por esta razón, dadas las características requeridas para el funcionamiento del sistema, se determina que

la configuración lumínica más apta es del tipo posterior difusa empleando un posicionamiento disperso entre partículas.

En última instancia y de acuerdo con la experimentación anterior, se explica el diseño final del prototipo y los materiales usados en su construcción. El sistema de visión artificial propuesto se compone de 3 sub-módulos principales, la base luminosa, la base de soporte de dispersión y la caja de aislamiento de luz y soporte de placa lógica.

En cuestión a las medidas de la base del prototipo, inicialmente se ubicó el material de grava en el suelo con el fin de observar el área total que abarca dicho material.

El primer sub-módulo corresponde a la base luminosa, tal y cómo se puede validar en la Figura 9, este se compone de una placa de madera de dimensiones 80 cm x 80 cm x 2 cm la cual integra en su cara superior 7 tiras led de color blanco. Cada una de 71 cm, las cuales se encuentran conectadas eléctricamente entre sí en configuración paralela de tal forma que se conserve la intensidad lumínica a lo largo de la placa. Estas medidas de la base luminosa corresponden al área que abarca la cantidad de material de grava.




Figura 9. Base luminosa para el módulo hardware del sistema propuesto. Fuente propia.

El siguiente sub-módulo corresponde a la base de soporte para la dispersión del sistema, se compone de una base en vidrio y una base en acrílico ubicadas sobre la cara superior de la base luminosa. Para la construcción de estas dos bases se tuvo en cuenta principalmente la cantidad de material que tendría que soportar, por esta razón se construyó un marco en madera de dimensiones 80 cm x 80 cm x 2 cm, con un agujero central de 62 cm x 62 cm para ubicar una placa de vidrio de 68 cm x 68 cm x 5 mm. Esto se hizo con el fin de tener una

base sólida y resistente, que permitiera el paso de la luz proveniente de la base luminosa. Finalmente se encuentra la base de acrílico blanco de 68 cm x 68 cm x 2 mm ubicada por encima de la base de vidrio, la cual entra en contacto directo con el material. De esta forma, se produce el mayor contraste posible siempre y cuando no haya influencia de ningún tipo de luz exterior. La Figura 10 corresponde a la construcción final del módulo de base de soporte.



Figura 10. Base de soporte para el modulo hardware del sistema propuesto. Fuente propia.

Por último, en el sistema de visión artificial, se encuentra la caja de aislamiento de luz. Esta caja fue elaborada con el aglomerado de madera MDF, debido a que de esta forma el módulo que cierra el prototipo no genera una carga excesiva sobre la base del mismo. Adicionalmente se hizo una apertura que permitiera la salida del flex de la cámara para su posterior conexión (ver Figura 11). Las dimensiones de la caja aislante son 72.5 cm x 72.5 cm x 82 cm, con 5 caras cubiertas y una cara que encaja en los sub-módulos bases.




Figura 11. Modulo fotogrfico del sistema propuesto. Fuente propia.

Tal como se describe en [11], [12] para la creaci3n del sistema de visi3n artificial propuesto, se implement3 un ordenador de procesamiento l3gico Raspberry Pi. Esto gracias a que sus dimensiones en conjunto con su bajo costo hacen que esta tipologa de computadores sea perfecta para este tipo de aplicaciones. Adicionalmente estos ordenadores cuentan en su interior con un ncleo basado en Linux que aligera los procesos, propiciando un ambiente 3ptimo para la ejecuci3n de tareas de un nico hilo. Por esta raz3n se decide optar por usar una placa Raspberry Pi 3 con 1 Gb de RAM, 4 ncleos de 64 bits ARM a 1.2 GHz Adems, fue utilizado un m3dulo fotogrfico diseado especialmente para esta placa. Su sensor 3ptico, cuenta con una resoluci3n de 5 megapxeles con un lente de foco fijo, el cual tiene la capacidad de capturar imgenes de hasta 2592x1944 pxeles y soporta video en 1080p a 30 cuadros por segundo (fps).



Figura 12. Prototipo final del sistema para visión artificial. Fuente propia.

3.2. Modulo software

Para esta sección se expone el proceso de diseño e implementación de dos sub-módulos, el primero aplica el procesamiento digital de imágenes para encontrar las partículas del material y obtener el conjunto de datos; el segundo implementa algoritmos de aprendizaje automático para la clasificación de las partículas, la predicción de su peso para finalmente encontrar su distribución. Tanto la construcción del conjunto de datos, como el entrenamiento de los modelos, fueron realizados siguiendo el marco de trabajo de CRISP-DM (*Cross Industry Standard Process for Data Mining*)[38].

La Figura 13 muestra las fases propuestas por dicha metodología que fueron implementadas en la presente investigación. El modelo CRISP-DM ofrece el ciclo de vida de un proyecto de minería de datos. Este contiene las fases del proyecto, así como sus respectivas tareas y resultados. Este ciclo de vida se desglosa en seis fases interconectadas entre sí por flechas que expresan las relaciones más relevantes y frecuentes: comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación y despliegue.

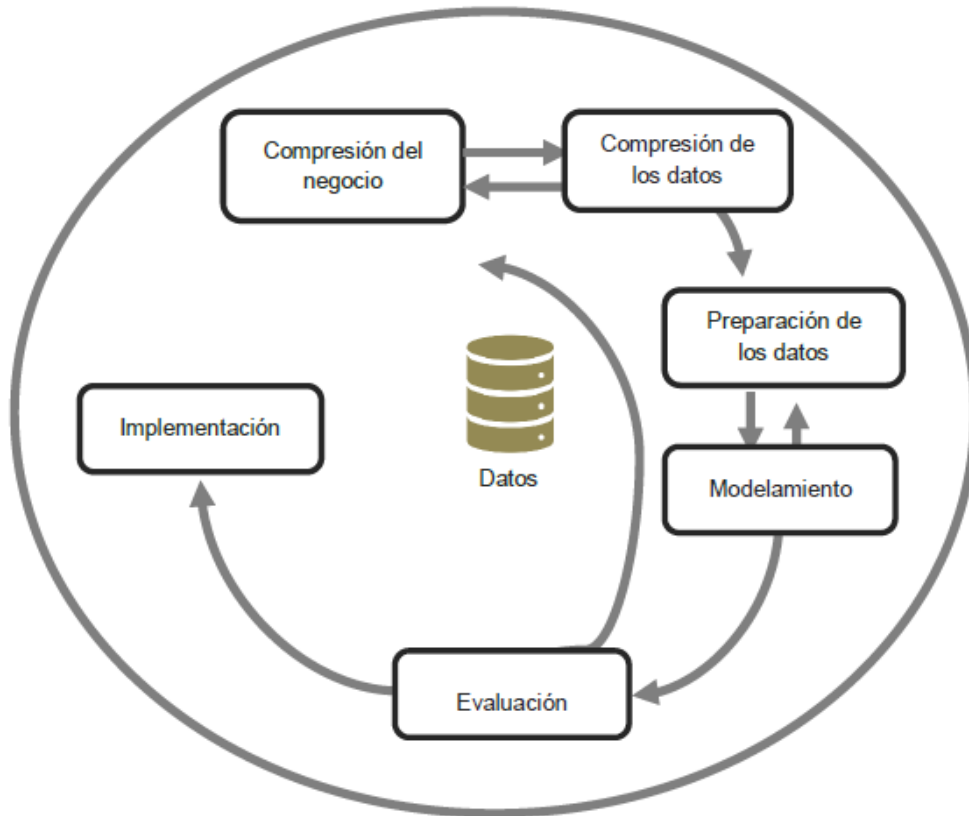


Figura 13. Fases propuestas por el modelo CRISP-DM. Adaptado de [38].

3.2.1. Modulo para la segmentación de imágenes y captura de datos

En este primer sub-modulo se lleva a cabo la recolección de los datos para el entrenamiento del modelo de aprendizaje automático, adicionalmente se realiza una exploración y descripción de dichos datos obtenidos. Teniendo en cuenta las fases del modelo CRISP-DM, en esta sección se implementan la comprensión de los datos y la preparación de los mismos.

3.2.1.1. Creación del conjunto de datos

Como primera medida, se realizó un análisis de las variables que pueden influir en los modelos de aprendizaje automático para la clasificación de las partículas y la obtención de su peso teniendo en cuenta las variables influyen en la granulometría tradicional. Principalmente, las variables para realizar la granulometría tradicional son el tamaño y el peso. El tamaño, ayuda a la clasificación de las partículas según el tamiz que las retiene, y el peso permite calcular el porcentaje pasante en cada uno de los tamices para determinar la distribución de dichas partículas. Con esto en mente, se determinaron las siguientes variables para los modelos de aprendizaje automático:

- **Lado1:** medida en centímetros del ancho.
- **Lado2:** medida en centímetros del largo.
- **Área piedra:** medida en centímetros cuadrados del área.
- **Área cuadrangular:** medida en centímetros cuadrados del área máxima que abarca.
- **Diagonal:** medida en centímetros de la diagonal que forma el área.
- **Forma:** clasificación según su forma.
- **Tamiz:** clasificación según el tamiz que la retiene.
- **Peso:** medida en gramos del peso de cada partícula.

Inicialmente, el módulo creado para la segmentación de imágenes y captura de datos realizó la captura de la imagen del material esparcido en el prototipo mediante el módulo fotográfico del prototipo.

Como se puede apreciar, las fotografías capturadas cuentan con un contorno negro (ver Figura 14). Ese contorno son las paredes del prototipo que el módulo fotográfico alcanza a capturar en la fotografía. Por lo siguiente, este módulo selecciona los 4 vértices que conforman el contorno de la placa para crear una nueva imagen, de tal forma que solo se pueda observar las partículas dentro de la placa blanca (ver Figura 15).




Figura 14. Imagen material para conjunto de entrenamiento. Fuente propia.




Figura 15. Imagen material para conjunto de entrenamiento sin contorno negro. Fuente propia.

Con la nueva imagen creada, el módulo procede a convertir la imagen a escala de grises, aunque en la imagen original se observa el contraste entre las partículas y el fondo. Luego aplica el filtro gaussiano para eliminar el ruido de la imagen causado por la iluminación del prototipo. Una vez eliminado el ruido de la imagen, el módulo implementa el filtro

Canny usado en la sección anterior, con el fin de detectar todos los bordes que se encuentran en la imagen (Ver Figura 16).

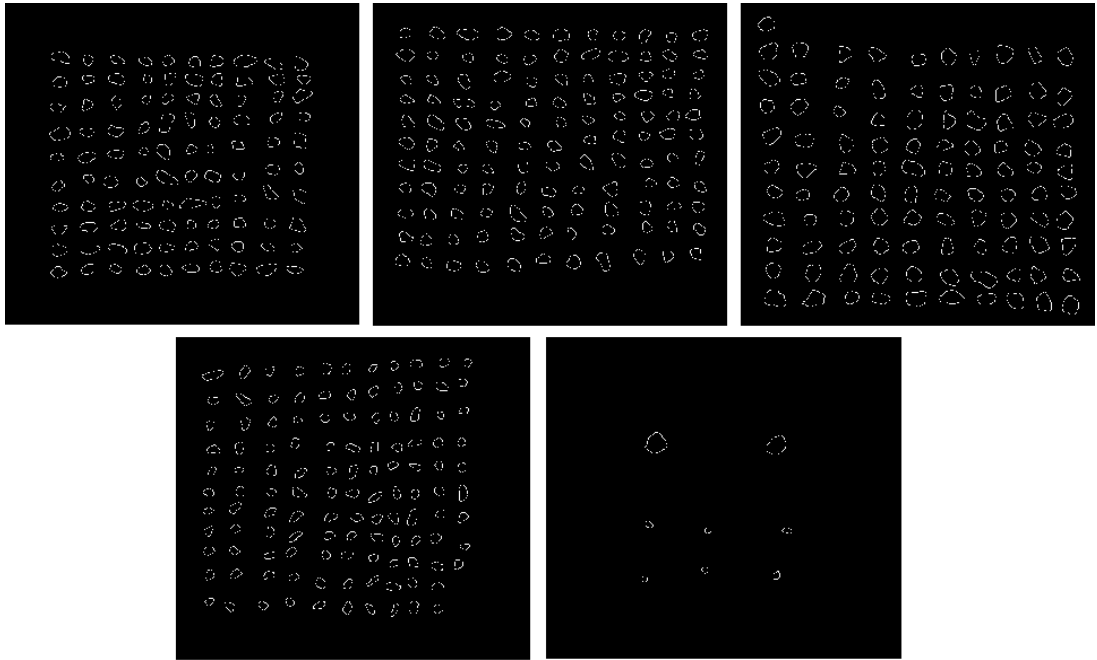


Figura 16. Resultado de implementación de filtro *Canny* (detección de contornos).
Fuente propia.

Luego, el módulo analiza si dichos bordes son contornos o no. De tal forma selecciona todas y cada una de las partículas que se encuentran en la imagen creando una lista con sus contornos. A continuación, con la lista de contornos el modulo recorre uno por uno (ver Figura 17), y se implementa la librería OpenCv de Python para hallar su forma elíptica, su forma cuadrangular y con ello, el largo y ancho de la partícula, su área, el área cuadrangular, su diagonal y su forma (comparando su forma elíptica y cuadrangular determinando a qué figura se asemeja más).




Figura 17. Captura de datos a partir de las características de cada partícula.
Fuente propia.

Para las variables de tamiz y peso, se practicó la granulometría tradicional a la muestra utilizada para encontrar la clasificación según el tamiz que la retiene y posteriormente a cada una determinar su peso en gramos. Manualmente se agregaron estos datos a una lista.

Para finalizar, el módulo crea un *dataframe* con todos los datos de cada una de las partículas del material (ver Figura 18), formando el conjunto para el entrenamiento de los modelos de aprendizaje automático.

	Lado 1	Lado 2	Area piedra	Area cuadrangular	Diagonal	Forma	Tamiz	Peso
13	2.22	2.67	4.42	6.01	3.47	Ovalada1	Media Pulgada	4.9
368	1.73	1.11	1.47	1.83	2.05	Ovalada2	3/8 Pulgada	3.0
235	3.02	2.95	6.42	8.92	4.22	Ovalada1	3/4 Pulgada	15.7
143	1.82	1.57	2.08	2.85	2.40	Ovalada1	Media Pulgada	3.7
232	2.16	3.39	5.28	7.33	4.02	Ovalada2	3/4 Pulgada	12.0
...
81	2.40	1.90	3.62	4.56	3.06	Ovalada1	Media Pulgada	4.0
297	3.31	2.73	7.15	9.00	4.29	Circular	3/4 Pulgada	20.6
330	1.94	1.61	2.35	3.00	2.52	Ovalada1	3/8 Pulgada	2.8
399	1.86	1.33	1.79	2.52	2.28	Ovalada1	3/8 Pulgada	2.7
331	1.29	1.69	1.77	2.10	2.13	Circular	3/8 Pulgada	3.1

Figura 18. Ejemplo de algunas instancias del conjunto de datos construido. Fuente propia.

3.2.1.2. Análisis exploratorio de los datos (EDA)

La fase de análisis exploratorio de los datos está compuesta por varias tareas, entre las que se encuentran: identificar el tipo de variables, encontrar datos nulos, valores atípicos y la distribución de cada una de las variables, además de un análisis bivariado entre las variables independientes y dependientes.

- **Identificación de variables:**

La Tabla 2 muestra una descripción de cada una de las variables con las que cuenta el conjunto de datos creado anteriormente. Esto determina cómo realizar el análisis de los datos según sea su tipo (Numérico o Categórico).

Tabla 2. Identificación de variables del conjunto de datos. Fuente propia.

Variable	Tipo de dato	Categoría	Tipo de variable
Lado 1	Numérico	Continuo	Independiente
Lado 2	Numérico	Continuo	Independiente
Área piedra	Numérico	Continuo	Independiente
Área cuadrangular	Numérico	Continuo	Independiente
Diagonal	Numérico	Continuo	Independiente
Forma	Categórico	Nominal	Independiente
Tamiz	Categórico	Nominal	Dependiente
Peso	Numérico	Continuo	Dependiente

- **Búsqueda de datos nulos:** palabras como “*null*” o “*NaN*” (*Not a Number*), incluso espacios en blanco fueron buscados para verificar que no existieran datos nulos en el conjunto de datos. Para esto, la librería Pandas de Python, ofreció la cantidad de variables (columnas), el tipo de dato de cada una, si existen datos nulos, y la cantidad total de datos en el *dataframe*. Como muestra la Figura 19, se creó un conjunto con 428 datos que van desde el índice 0 al índice 427, que cuenta con 8 variables (columnas) cada una sin datos nulo. También, describe los tipos de datos, siendo *float64* para datos numéricos y *object* para datos categóricos.

```

<class 'pandas.core.frame.DataFrame'>
Int64Index: 428 entries, 0 to 427
Data columns (total 8 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Lado 1                 428 non-null    float64
1   Lado 2                 428 non-null    float64
2   Area piedra           428 non-null    float64
3   Area cuadrangular     428 non-null    float64
4   Diagonal              428 non-null    float64
5   Forma                 428 non-null    object
6   Tamiz                 428 non-null    object
7   Peso                  428 non-null    float64
dtypes: float64(6), object(2)

```

Figura 19. Información del conjunto de datos. Fuente propia.

- **Valores atípicos y distribución de las variables:** para la detección de valores atípicos se utilizó un gráfico de caja para cada una de las variables de tipo numérico, y un histograma para observar su distribución.

En la Figura 20, se observa que únicamente la columna de la variable 'Diagonal' no cuenta con valores atípicos, a diferencia del resto de variables donde sí se encuentran este tipo de datos identificados por los puntos azules en forma de rombo. Estos valores atípicos no fueron eliminados del conjunto de datos porque no fueron generados por un error de entrada del sistema, tampoco por problemas del proceso; simplemente fueron datos reales pertenecientes a las piedras que hacían parte del material de estudio. Adicionalmente, se observa en los histogramas, que la distribución de todas las variables numéricas, no corresponden a una distribución normal, estas cuentan con una distribución sesgada hacia el lado derecho y evidencian los valores atípicos mencionados anteriormente encontrados en los gráficos de caja correspondientes. Con todo esto, se determinó que para el análisis bivariado en las variables numéricas se deben aplicar pruebas para datos no paramétricos, ya que la distribución de las variables numéricas no es de forma normal [39].

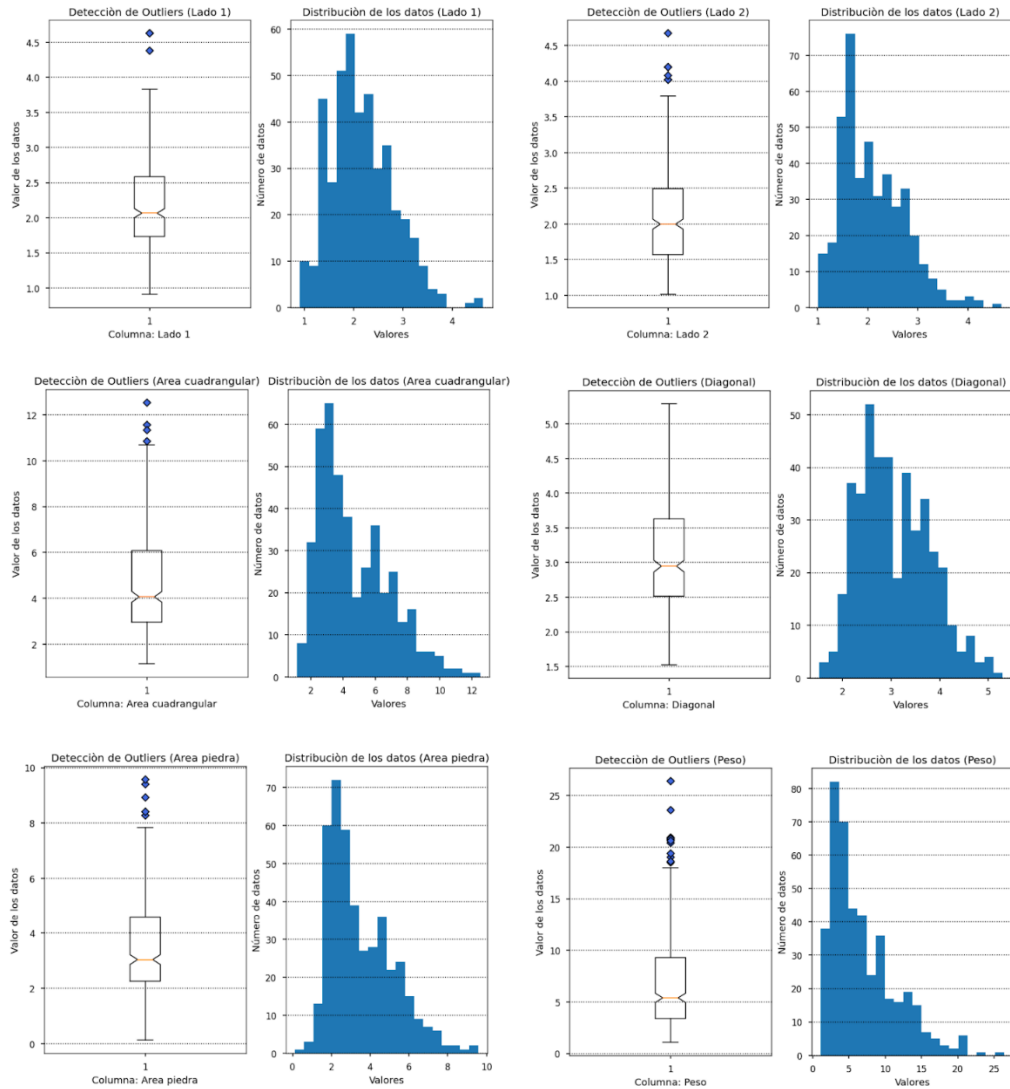


Figura 20. Gráficos de caja e histogramas para variables de tipo numérico.
Fuente propia.

Para las variables categóricas se utilizó un gráfico de barras para determinar la frecuencia de sus datos:

El gráfico de barras para la variable 'Forma' (ver gráfica izquierda de la Figura 21), evidencia que el dato con mayor frecuencia es el de tipo 'Ovalado2' seguido del tipo 'Circular' y 'Ovalado1', lo que indica que la mayoría de piedras cuentan con una forma cercana a una circunferencia ya sea alargada o no. También muestra que del tipo 'cuadrada' hay pocos registros (solo 2 registros) y de forma 'Rectangular' hay cero datos ya que ni siquiera se encuentra esa opción en la gráfica.

Para el gráfico de la variable 'Tamiz' (ver gráfica derecha de la Figura 21), se observa que existen 200 datos para el valor de 'Media Pulgada' siendo

el de mayor frecuencia en esta variable. Seguido del valor '3/8 Pulgada' y '3/4 Pulgada' con más de 100 observaciones cada una, y por último para el valor de 'Número 4' y '1 Pulgada' con menos de 10 datos cada una. Ya que se busca clasificar las piedras según el tamiz que las retiene, vemos que es un conjunto de datos desbalanceado, porque sus valores no cuentan con el mismo número de observaciones, y es bastante notoria la diferencia entre ellas, lo que podría causar errores para la clasificación de las mismas.

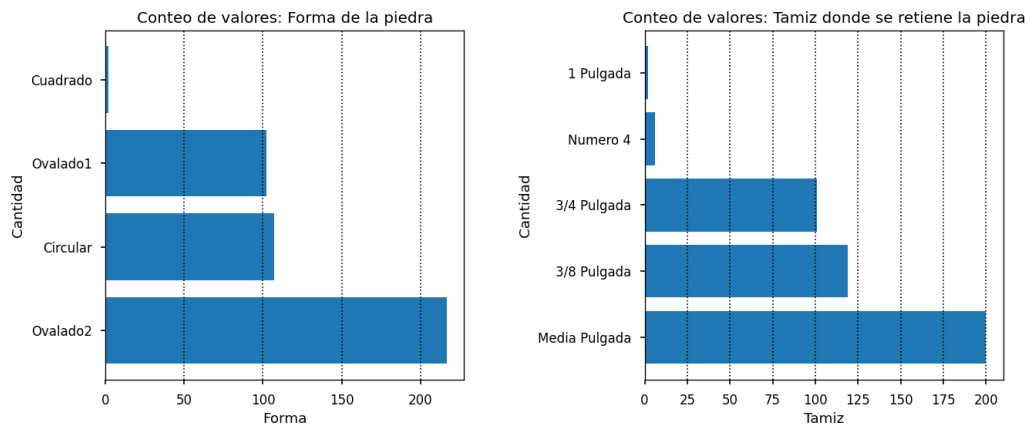


Figura 21. Gráficos de barras para variables categóricas. Fuente propia.

- **Análisis bivariado:** para este análisis se buscó la relación entre las variables independientes con las variables dependientes.

- Variable dependiente 'Tamiz':

Para las variables numéricas independientes, se practicó el test de *Kruskal- Wallis*, dado que las variables del conjunto de datos no se encuentran distribuidas normalmente. Este test es una prueba para datos no paramétricos que determina si existe o no una diferencia estadísticamente significativa entre las medianas de tres o más grupos independientes [39].

La prueba de *Kruskal-Wallis* utiliza las siguientes hipótesis nulas y alternativas:

La hipótesis nula: la mediana es igual en todos los grupos.

La hipótesis alternativa: la mediana no es igual en todos los grupos.

En el presente trabajo de grado, el objetivo del test es demostrar que en cada grupo de clasificación de variable 'Tamiz', la mediana de cada variable independiente es distinta, y probar que si influye su valor en la clasificación.

Según los resultados que muestra la Tabla 3 el valor de p en cada una de las variables es menor a 0.05 lo que rechaza la hipótesis nula donde la mediana es igual en cada grupo de clasificación de la variable 'Tamiz', lo que prueba que las demás variables del conjunto de datos si influyen en la clasificación de las piedras.

Tabla 3. Resultados del test de Kruskal- Wallis con la variable Tamiz.
Fuente propia.

Variable	Coficiente <i>Kruskal-Wallis</i>	Valor de p
Lado 1	134.99	3.3307^{-28}
Lado 2	205.80	2.1275^{-43}
Área piedra	273.83	4.7441^{-58}
Área cuadrangular	261.57	2.0876^{-55}
Diagonal	235.07	1.06^{-49}

Finalmente, para la única variable categórica independiente, se practicó el test *Chi-squared*, con el fin de encontrar si hay dependencia o no entre ambas variables categóricas, en este caso entre la variable 'Forma' y 'Tamiz'. Este test se calcula por medio de la suma de la diferencia al cuadrado entre los datos observados (O) y los datos esperados (E), dividida por los datos esperados, como muestra la siguiente fórmula [39]:

$$X^2 = \sum \left(\frac{(O - E)^2}{E} \right)$$

La prueba de *Chi-squared* utiliza las siguientes hipótesis nulas y alternativas:

La hipótesis nula: ambas variables son independientes.

La hipótesis alternativa: las variables tienen algún grado de asociación o relación.

Como resultado se obtuvo un valor de 35.87 como coeficiente de *Chi-squared* y un valor de p de 0.0003. Como dicho valor de p es menor a

0.05, este rechaza la hipótesis nula, la cual indica que ambas variables son independientes, por lo cual determina que la variable 'Forma' y 'Tamiz' tienen un grado de asociación o relación, siendo la forma de las piedras un dato significativo para la clasificación del tamiz que las retiene.

- Variable dependiente 'Peso':

Para las variables numéricas independientes se utilizaron gráficos de dispersión para evidenciar dicha relación, además del test de correlación de *Spearman* [40].

La Figura 22 en sus gráficos de dispersión muestra que todas las variables numéricas tienen una relación directa con la variable dependiente 'Peso', evidenciando que con estos datos es posible predecir el peso de las piedras.

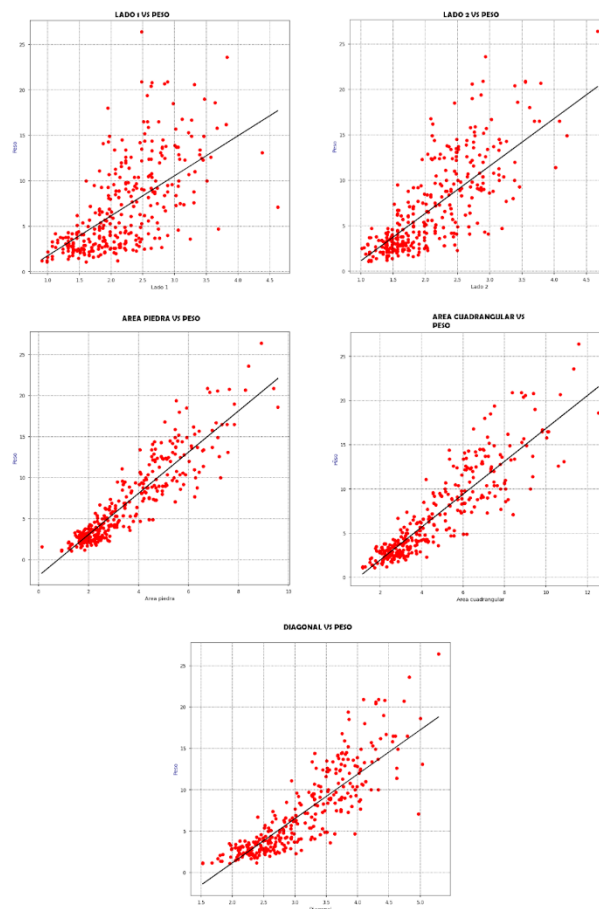


Figura 22. Gráficos de dispersión variables independientes vs Peso.
Fuente propia.

La Tabla 4 confirma esa relación directa que refleja los gráficos de dispersión. Todos cuentan con una relación directa bastante fuerte con la variable del peso, ya que su valor de coeficiente es mayor a 0.5 asimismo el valor de p es menor que 0.05 en todas las variables, lo que determina que esas relaciones son significativas.

Tabla 4. Resultados del test de correlación de *Spearman* con la variable Peso. Fuente propia.

Variable	Valor de correlación	Valor de p
Lado 1	0.67	4.3102^{-56}
Lado 2	0.75	1.5744^{-79}
Área piedra	0.91	1.0483^{-171}
Área cuadrangular	0.90	2.7778^{-157}
Diagonal	0.88	8.2028^{-141}

Por último, para las variables categóricas independientes, se practicó el test de *Kruskal-Wallis*, con el fin de determinar si son significativas para la variable dependiente, en este caso para el 'Peso'.

Según los resultados que muestra la Tabla 5 el valor de p en la variable 'Forma' es mayor a 0.05 lo que aprueba la hipótesis nula donde la mediana es igual en cada grupo de la variable 'Forma', lo que determina que dicha variable no influye en el valor del peso. A diferencia de la variable 'Tamiz' la cual cuenta con un valor de p menor a 0.05, el cual rechaza la hipótesis nula y determina que si influye en el valor del peso de cada una de las piedras.

Tabla 5. Resultados del test de Kruskal- Wallis con la variable Peso.
Fuente propia.

Variable	Coficiente <i>Kruskal-Wallis</i>	Valor de <i>p</i>
Forma	4.49	0.2125
Tamiz	326.01	2.6512^{-69}

Luego de los procesos mencionados anteriormente, se obtuvo el conjunto de datos para el entrenamiento de los algoritmos de aprendizaje automático. Para la clasificación se utilizaron todas las variables independientes, mientras que para la predicción del peso se utilizaron la variable Tamiz y todas las variables independientes exceptuando la variable Forma.

3.2.2. Módulo para la clasificación de cada partícula y estimación de su peso.

La presente sección se centra en la construcción de dos modelos de aprendizaje automático, donde el primero permite clasificar las partículas del material según el tamiz que la retiene y el segundo pueda arrojar una estimación del peso de cada partícula. Se tomó como base CRISP-DM, específicamente la fase de modelado de dicho marco de trabajo. A continuación, en la Figura 23, se exponen las tres actividades realizadas como parte del proceso de modelamiento en este proyecto.




Figura 23. Etapas que conforman la fase de modelado. Adaptado de [38].

Para cumplir el objetivo, se realizó una evaluación de cada modelo después de construido por medio de dos enfoques:

El primer enfoque permite mejorar la precisión fuera de la muestra, ya que divide el conjunto de datos en dos grupos diferentes. Esto facilita una evaluación más precisa, debido a que el conjunto de datos para validación no hace parte del conjunto de datos para entrenamiento, logrando así una solución más real con respecto al primer enfoque.

Como se observa en la Figura 24 el primer grupo es para entrenamiento y el segundo es un grupo de datos para validar el algoritmo, siendo grupos mutuamente excluyentes.




Figura 24. Representación del primer enfoque. Fuente propia.

Por último, aparece un segundo enfoque, el cual permite mejorar la precisión del modelo al utilizar nuevos datos, llamado validación cruzada. Este consiste en dividir el conjunto de datos en k grupos para luego tomar uno de ellos como conjunto de validación, mientras que los restantes serán el conjunto de datos para el entrenamiento del modelo. Esto se repite k número de veces, durante las cuales cada uno de los grupos es utilizado como conjunto de validación (ver Figura 25). Finalmente, se promedian todos los resultados para generar así el modelo final [41].

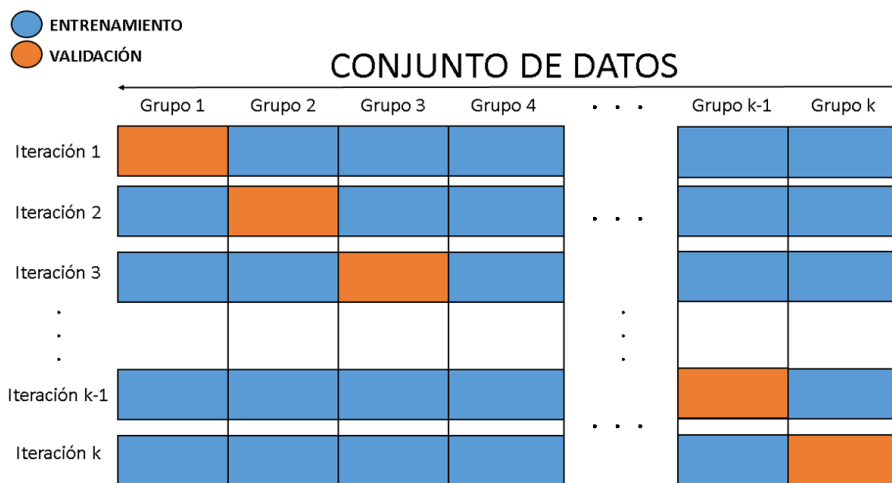


Figura 25. Representación del segundo enfoque (validación cruzada). Fuente propia.

3.2.2.1. Modelo de clasificación

Para la creación de este modelo, se tuvieron en cuenta las diferentes investigaciones relacionadas con el proyecto, donde su aplicación es para clasificación. El algoritmo más utilizado en esos trabajos fue el k - *nearest Neighbors (KNN)*, sin embargo, en el presente trabajo de grado se adicionaron 5 algoritmos más, dedicados a la clasificación de conjuntos

de datos en aprendizaje automático: *support vector machine classifier (SVC)*, *decision tree*, *random forests*, *bagging classifier*, *gradient boost classifier*.

Con esto, se utilizan cada uno de los algoritmos pre-seleccionados con el conjunto de datos creado en la sección anterior.

- Métrica de evaluación:

Para poder evaluar el modelo de clasificación con el objetivo de clasificar cada una de las partículas del material según el tamiz que la retiene, se deben comparar los datos predichos frente a los datos reales. A continuación, se describe la métrica utilizada para la evaluación del desempeño de cada uno de los algoritmos mencionados, que serán expuestos en esta sección.

- **Accuracy (Exactitud)** [42]: Es una de las métricas para evaluar los modelos de clasificación, la cual indica la relación entre el número de predicciones correctas y el número total de muestras de entrada. Ahora bien, para asegurar alta confiabilidad en los resultados arrojados es necesario tener en cuenta que se deben tener la misma cantidad de muestras pertenecientes a cada una de las clases dentro del conjunto de datos:

$$Accuracy = \frac{Cantidad\ de\ predicciones\ correctas}{Cantidad\ total\ de\ predicciones}$$

Con la métrica de evaluación descrita, y según el primer enfoque para evaluar los algoritmos, se implementó la función *train_test_split* la cual divide el conjunto de datos en dos datos de validación y datos de entrenamiento [43], por lo cual para este enfoque nuestro conjunto de validación representa el 20% del conjunto de datos total, y el 80% restante es el conjunto de datos para entrenamiento del algoritmo, obteniendo los siguientes resultados:

Los resultados en la Tabla 6 muestran que el algoritmo con mejor desempeño es el *gradient boost classifier*, seguido muy de cerca por *random forest* y *bagging classifier*. Luego se encuentran los algoritmos, *decision tree* y *support vector machine*, mientras que el *knn* presenta un menor porcentaje de precisión.

También se observa que con este enfoque, los algoritmos arrojan porcentajes de precisión menores al 81%, debido a que al particionar el conjunto de datos, los datos que hacen parte del conjunto de validación,

no harán parte del modelamiento, perdiendo así datos que podrían mejorar la precisión del modelo [44].

Tabla 6. Porcentaje de exactitud de los algoritmos de clasificación para el primer enfoque. Fuente propia.

Algoritmo	Train test Split
<i>KNN</i>	68.21%
<i>SVC</i>	70.54%
<i>Decision tree</i>	77.51%
<i>Random Forest</i>	79.84%
<i>Bagging</i>	79.06%
<i>Gradint Boost</i>	80.62%

Siguiendo con el último enfoque, para evaluar los algoritmos se utiliza la función *cross_validation*, donde se determina el parámetro *k*, indicando el número de subconjuntos en el que será particionado el conjunto de datos total.

En el caso de esta investigación, se utilizaron tres diferentes valores para $k = [3,5,10]$, obteniendo los siguientes resultados:

La Tabla 7 muestra los resultados de la validación cruzada. En esta validación los algoritmos con mejor desempeño fueron *random forest* y *gradient boost classifier* teniendo el mejor resultado sobrepasando el 86% de precisión. A continuación, se encuentran *decision tree* y *bagging classifier* los cuales están entre el 82-85% de precisión. Por último, los algoritmos *support vector machine* y *knn* obtuvieron los menores porcentajes de precisión.

Tabla 7. Porcentaje de exactitud de los algoritmos de clasificación para validación cruzada. Fuente propia.

Algoritmo	VALIDACIÓN CRUZADA	
	Valor K	Promedio de exactitud
<i>KNN</i>	k = 3	74.76 %
	k = 5	74.06 %
	k = 10	74.79 %
<i>SVC</i>	k = 3	74.53 %
	k = 5	74.52 %
	k = 10	74.76 %

<i>Decision Tree</i>	k = 3	84.57 %
	k = 5	82.47 %
	k = 10	86.21 %
<i>Random Forest</i>	k = 3	85.51 %
	k = 5	86.44 %
	k = 10	87.37 %
<i>Bagging</i>	k = 3	84.57 %
	k = 5	83.63 %
	k = 10	83.64 %
<i>Gradient Boost</i>	k = 3	85.51 %
	k = 5	86.91 %
	k = 10	85.51 %

Adicionalmente, para realizar una buena selección del algoritmo, existe una técnica de validación cruzada llamada *grid_search*, la cual se utiliza para determinar los hiperparámetros óptimos de un modelo de aprendizaje automático. Los hiperparámetros son parámetros ajustables que permiten controlar el proceso de entrenamiento de un modelo, en búsqueda de producir el mejor rendimiento.

La Figura 26 representa el funcionamiento de *grid_search*, la cual realiza pruebas con cada una de las combinaciones posibles entre los diferentes valores de hiperparámetros. Con ello encuentra los valores óptimos dentro de un algoritmo para lograr arrojar mejores resultados [45].

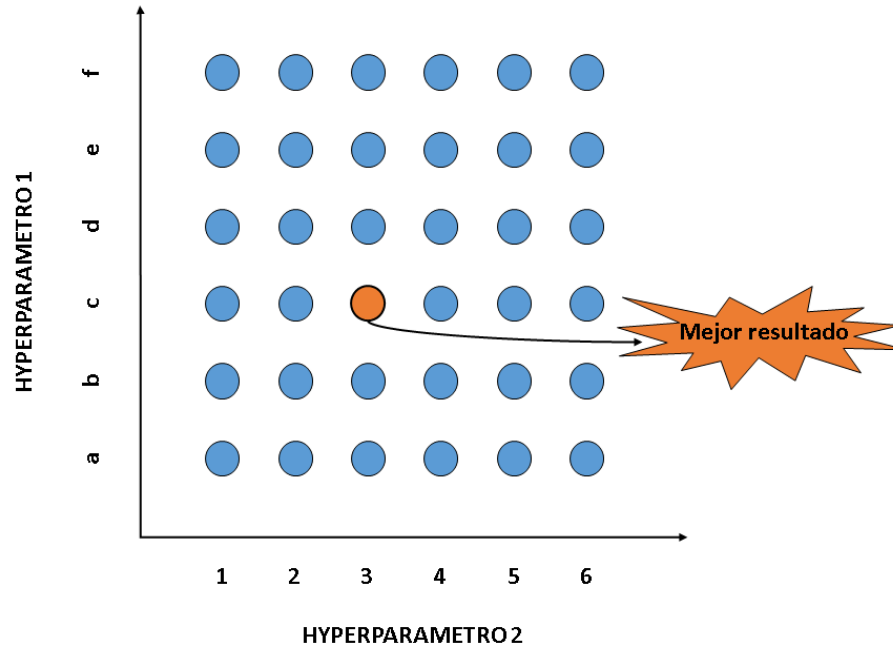


Figura 26. Técnica de validación cruzada: *Grid Search*. Fuente propia.

En este proyecto se implementó *grid_search*, por medio de la librería Scikit-learn de Python, con diferentes valores en cada uno de los hiperparámetros para cada uno de los algoritmos pre-seleccionados, variando el valor de *k*. Con todo esto, se obtuvieron los siguientes resultados, con los valores de sus hiperparámetros, respectivamente:

Según la Tabla 8, en la técnica utilizada los algoritmos con mejor desempeño siguen siendo *random forest* y *gradient boost classifier* aumentando su nivel de exactitud comparado con la tabla 7. A continuación, el algoritmo *decision tree* supera el 80% de exactitud en sus diferentes resultados, y por último *support vector machine*, *knn*, y *bagging classifier*, siendo los algoritmos con los resultados más bajos.

Tabla 8. Porcentaje de exactitud de los algoritmos de clasificación para *grid_search*. Fuente propia.

Algoritmo	GRID SEARCH		
	Valor K	Promedio de exactitud	Parámetros
KNN	k = 3	75.23 %	n_neighbors': 2
	k = 5	76.15 %	'n_neighbors': 10
	k = 10	75.47 %	'n_neighbors': 10

<i>SVC</i>	k = 3	78.96 %	'C': 100, 'class_weight': None
	k = 5	78.26 %	'C': 100, 'class_weight': None
	k = 10	78.27 %	'C': 100, 'class_weight': None
<i>Decision Tree</i>	k = 3	84.57 %	'class_weight': None, 'max_depth': 25, 'min_samples_split': 2
	k = 5	82.47 %	'class_weight': None, 'max_depth': 10, 'min_samples_split': 2
	k = 10	86.21 %	'class_weight': None, 'max_depth': 25, 'min_samples_split': 2
<i>Random Forest</i>	k = 3	85.97 %	'class_weight': None, 'max_depth': 20, 'n_estimators': 250
	k = 5	88.9 %	'class_weight': None, 'max_depth': 10, 'n_estimators': 100
	k = 10	91.02 %	'class_weight': None, 'max_depth': 20, 'n_estimators': 50
<i>Bagging</i>	k = 3	73.83 %	'max_samples': 20, 'n_estimators': 50
	k = 5	73.58 %	'max_samples': 20, 'n_estimators': 250
	k = 10	72.43 %	'max_samples': 20, 'n_estimators': 50
<i>Gradient Boost</i>	k = 3	86.91 %	'max_depth': 10, 'n_estimators': 250
	k = 5	86.9 %	'max_depth': 10, 'n_estimators': 250
	k = 10	87.61 %	'max_depth': 10, 'n_estimators': 250

3.2.2.2. Modelo de regresión

Según las investigaciones relacionadas con este proyecto, no se encontraron aplicaciones de modelos de regresión, por lo cual se utilizaron diferentes algoritmos de regresión, iniciando con el algoritmo de regresión lineal como principal opción, ya que este algoritmo tiene el enfoque más simple donde a partir del ajuste de una recta identifica la relación entre las variables independientes y la variable dependiente. Con lo anterior, lograr predecir el peso de cada partícula.

- Métrica de evaluación:

Para poder evaluar el modelo de regresión con el objetivo de estimar el peso de cada una de las partículas del material, igualmente se deben comparar los datos predichos con los datos reales. A continuación, se describe la métrica utilizada para la evaluación del desempeño del algoritmo.

- **Error cuadrático medio (*RMSE*, por sus siglas en inglés)** [46]: El error medio cuadrático se define como la raíz cuadrada de la media del cuadrado de todos los errores. El uso del *RMSE* es muy común, y se considera una excelente métrica de error de propósito general para las predicciones numéricas.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2}$$

donde:

O_i , son las observaciones

S_i , los valores predichos de una variable

n , el número de observaciones disponibles para el análisis.

El *RMSE* es medida de precisión válida siempre y cuando sea para comparar los errores de predicción de diferentes modelos o configuraciones de modelos para una variable concreta y no entre variables, ya que depende de la escala.

Las diferentes columnas del conjunto de datos son utilizadas por lo que se implementa una regresión lineal múltiple, obteniendo el siguiente resultado: $RMSE = 2.2073$.

Para poder validar dicha regresión es necesario que se cumplan 5 supuestos [47]:

1. **Linealidad:** Debe existir una relación lineal entre las variables dependientes y las variables independientes.
2. **Independencia:** No debe existir relación entre los términos residuales (errores).
3. **Homocedasticidad:** Los términos residuales(errores) deben tener varianza constante.
4. **Normalidad:** Los términos de error deben distribuirse normalmente.
5. **No colinealidad:** Las variables independientes no deben estar correlacionadas entre sí. La ausencia de este fenómeno se conoce como multicolinealidad.

Para el supuesto número 1 de: linealidad, se observó en la sección del análisis exploratorio de los datos que las variables independientes tienen relación lineal con respecto a la variable dependiente ('Peso'). Por lo tanto, cumple con este supuesto.

Para el supuesto número 2 de: independencia, se implementó la función *durbin_watson()*, la cual realiza el test de *Durbin-Watson*, que determina si los residuos del modelo de regresión están auto correlacionados. El resultado de esta función, debe estar dentro del rango 1.5 y 2.5 para considerar que la auto correlación de los datos no es significativa, y no es problemática para el modelo de regresión [47]. De esta manera, en el conjunto de datos del presente trabajo, se obtuvo un valor de 2.07, ubicándose dentro del rango establecido que indica que la auto correlación de los residuos no afecta el modelo de regresión. Por lo tanto, cumple con este supuesto.

Para el supuesto número 3 de: homocedasticidad, se graficaron los términos residuales(errores). Estos términos residuales (errores) se calculan como la diferencia que existe entre el valor observado de la variable y el valor estimado.

La grafica de errores vs puntos ajustados se utiliza para verificar que los residuos se encuentran distribuidos aleatoriamente y tienen una varianza constante. Lo ideal en esta grafica es que los puntos se ubiquen aleatoriamente a ambos lados del 0, con patrones no detectables.

La Figura 27 muestra que los puntos aparecen dispersos de forma aleatoria, tienen una varianza constante, y no cuentan con un comportamiento evidente, por esta razón cumplen con el supuesto de homocedasticidad.




Figura 27. Gráfica de errores. Fuente propia.

Para el supuesto número 4 de: normalidad, se implementa un histograma para evidenciar la distribución de los errores.

Como muestra la Figura 28, los errores están distribuidos de forma normal. Pero se evidencian valores atípicos en el extremo de la gráfica, aun así, cumpliendo con el supuesto de normalidad.




Figura 28. Histograma para representación de la distribución de los errores. Fuente propia.

Para el supuesto número 5 de: no colinealidad, se calculó la correlación de *Spearman* de las variables numéricas independientes utilizadas en el modelo.

En la Figura 29 se evidencia que la mayoría de las variables numéricas independientes cuentan con una fuerte correlación entre ellas, siendo algo obvio ya que las variables de ‘Área piedra’, ‘Área cuadrangular’ y ‘Diagonal’ son variables que dependen de las dos primeras variables. Por lo tanto, se presenta multicolinealidad y con esto no se cumple el último supuesto.

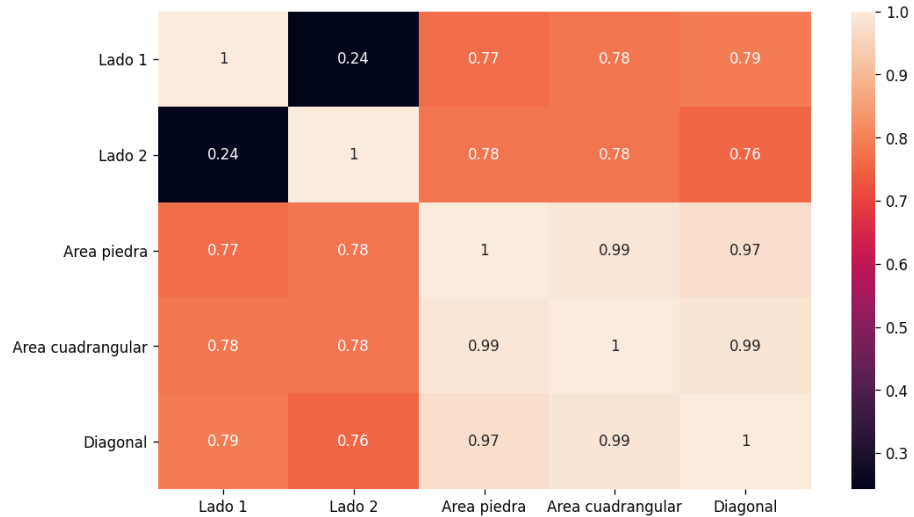


Figura 29. Mapa de calor de la correlación de Spearman entre variables independientes. Fuente propia

En resumen:

- Linealidad. Se cumple.
- Independencia. Se cumple.
- Homocedasticidad. Se cumple.
- Normalidad. Se cumple.
- No colinealidad. No se cumple, porque existe multicolinealidad.

Según lo anterior, el supuesto de “No colinealidad” no se cumple. Para ello se utilizó una alternativa conocida como regularización. La cual posee un método llamado “*Ridge*”, que ayuda a atenuar el efecto de correlación entre las variables penalizando los coeficientes de la regresión lineal [48].

En la implementación de la regresión “*Ridge*” se utilizaron diferentes valores para λ (grado de penalización), donde según la métrica utilizada el mejor resultado obtenido fue: $RMSE = 2.2085$.

La Tabla 9 muestra que el resultado de la regresión “*Ridge*” es mayor que el de regresión lineal, lo que indica que la alternativa de regularización utilizada no funciona correctamente para la creación de nuestro modelo, ya que el objetivo es disminuir el valor de RMSE. Esto ocurre ya que los datos no se encuentran normalmente distribuidos, como se probó anteriormente. Por lo tanto se utilizan otros modelos como *decision tree*, *random forest*, *bagging regressor* y *gradient boost regressor*, los cuales pueden ayudar a una mejor interpretación de los datos y obtener mejores resultados, ya que no requieren que los datos se encuentren distribuidos normalmente [49].

Tabla 9. Resultados de *RMSE* de regresión lineal y *Ridge*. Fuente propia.

Regresión	<i>RMSE</i>
Lineal	2.2073
<i>Ridge</i>	2.2085

Con la métrica de evaluación descrita, se obtienen los siguientes resultados para el primer enfoque de evaluación:

Teniendo en cuenta la Tabla 10 el algoritmo con mejor desempeño para el segundo enfoque es *random forest*, seguido por *gradient boost regressor* y *bagging regressor*, y por último *decision tree* el cual obtuvo un resultado menos favorable incluso peor comparado con la regresión lineal y “*Ridge*”.

Tabla 10 Resultados *RMSE* de los algoritmos de regresión para el primer enfoque. Fuente propia.

Algoritmo	<i>TRAIN TEST SPLIT</i>
<i>Decision tree</i>	3.1056
<i>Random forest</i>	1.6992

<i>Bagging</i>	2.024
<i>Gradient Boost</i>	2.1578

De igual forma, en la implementación de los algoritmos para el tercer enfoque se obtuvieron los siguientes resultados de evaluación:

Teniendo en cuenta la Tabla 11 para la validación cruzada el algoritmo que obtuvo mejores resultados es *random forest* teniendo el menor resultado para *RMSE* de 1.4903, seguido de *gradient boost regressor* y *bagging regressor*, y por último el algoritmo de *decision tree*.

Tabla 11. Resultados *RMSE* de los algoritmos de regresión para el segundo enfoque. Fuente propia.

Algoritmo	VALIDACIÓN CRUZADA	
	Valor K	<i>RMSE</i>
<i>Decision Tree</i>	k = 3	3.0405
	k = 5	2.5403
	k = 10	2.34075
<i>Random Forest</i>	k = 3	2.157
	k = 5	1.6072
	k = 10	1.4903
<i>Bagging</i>	k = 3	2.43355
	k = 5	1.7475
	k = 10	1.675
<i>Gradient Boost</i>	k = 3	2.52945
	k = 5	1.72135
	k = 10	1.6765

Finalmente, para la implementación de *grid_search*, se obtienen los siguientes resultados:

Para la Tabla 12, se evidencia el mismo orden que la tabla anterior en el desempeño de los algoritmos. El de mejor resultado con la técnica utilizada es *random forest*, seguido por *gradient boost regressor* y *bagging regressor*, y al final *decision tree* el algoritmo con peor desempeño.

Tabla 12. Resultados *RMSE* de los algoritmos de regresión para *Grid Search*.
Fuente propia.

Algoritmo	GRID SEARCH		
	Valor K	RMSE	Parámetros
<i>Decision Tree</i>	k = 3	3.0405	'max_depth': 25, 'min_samples_split': 2
	k = 5	1.94805	'max_depth': 10, 'min_samples_split': 10
	k = 10	1.62285	'max_depth': 25, 'min_samples_split': 10
<i>Random Forest</i>	k = 3	2.1581	'max_depth': 20, 'n_estimators': 50
	k = 5	1.59645	'max_depth': 10, 'n_estimators': 100
	k = 10	1.4685	'max_depth': 20, 'n_estimators': 250
<i>Bagging</i>	k = 3	2.19715	'max_samples': 20, 'n_estimators': 100
	k = 5	2.46205	'max_samples': 20, 'n_estimators': 250
	k = 10	2.19715	'max_samples': 20, 'n_estimators': 100
<i>Gradient Boost</i>	k = 3	2.42255	'max_depth': 5, 'n_estimators': 50
	k = 5	1.9018	'max_depth': 5, 'n_estimators': 250
	k = 10	1.6395	'max_depth': 5, 'n_estimators': 250

Con lo anterior expuesto, el algoritmo con mejor desempeño en el modelo de clasificación fue *random forest* obteniendo un 91.02 de exactitud en la clasificación de las partículas, siendo el mejor resultado entre todos los resultados obtenidos. Además, para el modelo de regresión el cual predice el peso de cada partícula, *random forest* obtuvo 1.4685 en la métrica utilizada para este modelo, siendo el mejor resultado entre todos los resultados obtenidos.

4. Resultados

4.1. Ejecución de la prueba

Una vez seleccionado el algoritmo con mejor desempeño para el modelo de clasificación y regresión, se realiza una prueba final con un material que no ha sido empleado para la creación del conjunto de datos de entrenamiento. Lo anterior con el objetivo de hacer una comparación entre la metodología desarrollada en este proyecto y la granulometría tradicional.

La Figura 30 muestra el diagrama de funcionamiento del sistema propuesto. En dicho diagrama se encuentra la serie de acciones que realiza el sistema, desde el vertimiento del material, pasando por la captura de las imágenes, también por la implementación de las técnicas de procesamiento digital de imágenes y los modelos de aprendizaje automático, hasta la obtención de resultados y la gráfica de su distribución.

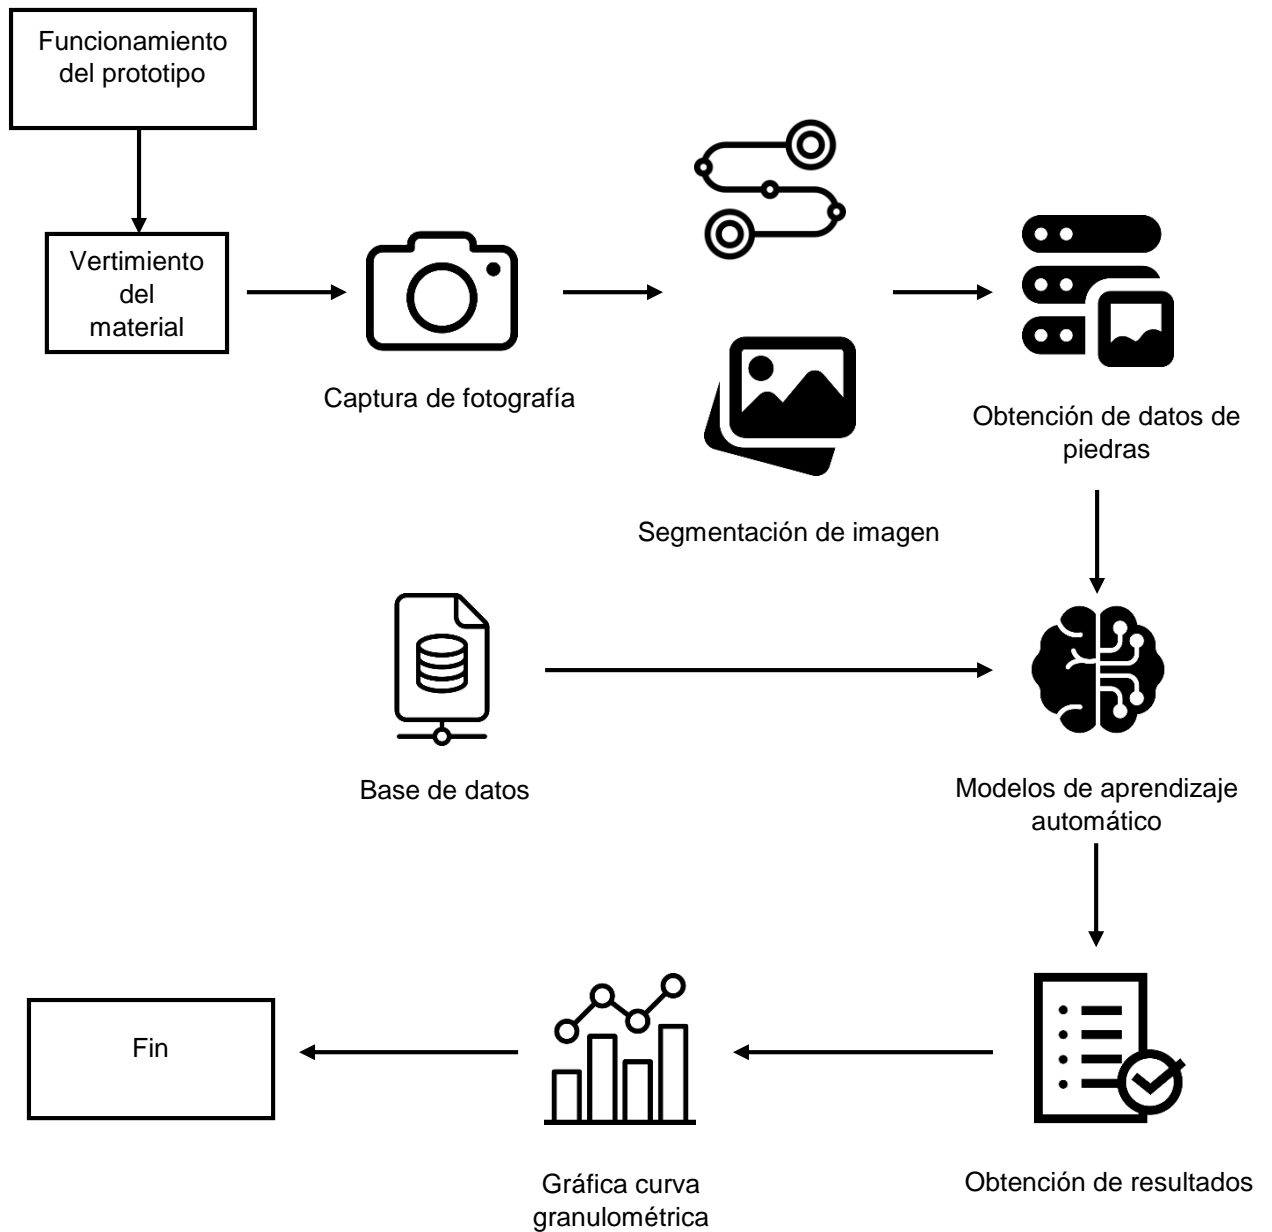


Figura 30. Diagrama de funcionamiento del sistema propuesto. Fuente propia.

La ejecución de la prueba inició con la captura de las imágenes del material a estudiar (ver Figura 31), las cuales posteriormente fueron segmentadas para reconocer cada una de las partículas que lo componen. Con esta segmentación se obtuvo el número de partículas de la muestra y los datos “Lado1”, “Lado2”, “Área piedra”, “Área cuadrangular”, “Diagonal” y “Forma” de cada una de ellas, creando el conjunto de datos de dicha muestra.




Figura 31. Imagen del nuevo material. Fuente propia.

Con los algoritmos seleccionados, el conjunto de datos de entrenamiento creado anteriormente, y los datos obtenidos del nuevo material, se clasificó cada una de las nuevas partículas según el tamiz que las retiene y se obtuvo el peso de cada una de ellas, información que permitió determinar el peso total de la muestra, el peso retenido en cada uno de los tamices, su porcentaje retenido y su porcentaje pasante (datos utilizados para obtener la curva granulométrica), como se observa en la Tabla 13.

El sistema propuesto en este proyecto predijo un peso total de 2671.54 gramos, correspondientes a 375 piedras encontradas. Todo el proceso se realizó durante 5 minutos con 4.6 segundos, donde 5 minutos corresponden a la organización del material en el sistema, y 4.6 segundos a la ejecución del módulo software, que va desde la captura de la imagen, pasando por su segmentación y adquisición de datos, también la implementación de los modelos de aprendizaje automático para obtener la clasificación de las piedras y la predicción de sus pesos, hasta el despliegue de los resultados y su gráfica.

Tabla 13. Resultados granulometría por el sistema propuesto del nuevo material.
Fuente propia

Tamiz	Abertura (mm)	Piedras retenidas	Peso Retenido (g)	Porcentaje retenido (%)	Porcentaje pasante (%)
1'	25.000	1	20.18	0.8	99.2
3/4'	19.000	114	1,465.76	54.9	44.4
1/2'	12.500	132	891.21	33.4	11.0
3/8'	9.500	107	264.94	9.9	1.1
4	4.750	21	29.45	1.1	0.0

La Figura 32 representa la curva granulométrica del material de estudio encontrada por el sistema propuesto, en general dicha curva se encuentra plasmando el porcentaje pasante con respecto a cada uno de los tamices.




Figura 32. Gráfica granulométría del sistema nuevo propuesto. Fuente propia.

Para realizar la comparación de los resultados obtenidos por el sistema propuesto en este proyecto (ver Figura 32), un geotecnólogo experto en el área realizó la granulometría tradicional (por tamizado) al mismo material usado en la prueba. El experto tardó, 25 minutos en el proceso de tamizado y pesado hasta la obtención de la gráfica, y encontró un peso total de 2745 gramos correspondientes a 375 piedras. Los resultados del experto se pueden observar en la Tabla 14 y Figura 33.

De igual forma, la Figura 33 muestra la curva granulométrica según los resultados encontrados por el experto en el material de estudio. Esta curva plasma el porcentaje pasante en cada uno de los tamices.

En primera medida, es posible identificar la disminución del tiempo, al comparar lo que tarda en concluir cada uno de los procesos. La granulometría mediante el sistema propuesto toma un total de 5 minutos con 4.6 segundos, lo que indica que su ejecución es 5 veces más rápida aproximadamente, con respecto a los 25 minutos que toma realizar la granulometría tradicional a la misma cantidad de material.

En segunda instancia, con respecto a los resultados, el sistema propuesto en este proyecto identificó 375 piedras al igual que la granulometría tradicional, lo que indica que el sistema se comporta de manera óptima ya que el módulo de segmentación de imagen reconoce todas las piedras del material estudio.

Con respecto al peso total del material, la granulometría tradicional calculó un peso total de 2745 gramos. El sistema calculó un peso total de 2671.54 gramos, al sumar todos los pesos predichos para cada una de las piedras. Con esto encontramos que el sistema cuenta con un porcentaje de error equivalente al 2.67%.

Tabla 14. Resultados granulometría tradicional del nuevo material. Fuente propia.

Tamiz	Abertura (mm)	Piedras retenidas	Peso Retenido (g)	Porcentaje retenido (%)	Porcentaje pasante (%)
1'	25.000	1	18.5	0.7	99.3
3/4'	19.000	98	1,459.9	53.2	46.1
1/2'	12.500	163	1,007.8	36.7	9.4
3/8'	9.500	107	239.5	8.7	0.7
4	4.750	6	8.1	0.3	0.4




Figura 33. Gráfica granulometría tradicional realizada por el experto. Fuente propia.

Por otro lado, el sistema fue capaz de clasificar todas las piedras encontradas entre los diferentes tamices que las retienen.

4.2. Discusión

La Tabla 15 muestra que en la clasificación de las piedras según el tamiz que las retiene, la clasificación en los tamices de 1 pulgada y $\frac{3}{8}$ de pulgada no presentan error, clasifican la misma cantidad de piedras como en la granulometría tradicional. Sin embargo, para los demás tamices como los de $\frac{3}{4}$ de pulgada y de $\frac{1}{2}$ pulgada, posee porcentajes de error del 16.32% y 19.01%

respectivamente, incluso para el tamiz número 4 clasifica 21 piedras donde solo son 6, teniendo un porcentaje de error del 250%, siendo bastante elevado, para una buena clasificación.

Lo anterior puede ser ocasionado por variables faltantes en el conjunto de datos de entrenamiento, por ejemplo, en la granulometría tradicional, una partícula puede ser retenida de forma horizontal, pero puede ser pasante por el mismo tamiz si su posición es vertical. En este sentido una de las limitaciones del sistema propuesto es que opera en dos dimensiones, considerando únicamente el ancho y largo de la partícula y no el alto de la misma, afectando la clasificación.

Tabla 15. Comparación clasificación de partículas Granulometría Tradicional vs Sistema propuesto. Fuente propia.

Tamiz	Granulometría Tradicional	Sistema propuesto	Porcentaje de error
1'	1	1	0.0%
3/4'	98	114	16.32%
1/2'	163	132	19.01%
3/8'	107	107	0.0%
4	6	21	250%

La Tabla 16 compara los resultados entre la granulometría tradicional y el sistema propuesto teniendo en cuenta el peso retenido en cada uno de los tamices. Esta señala que el tamiz de $\frac{3}{4}$ de pulgada con el menor porcentaje de error con un 0.40%, indicando que el peso retenido en dicho tamiz en el sistema propuesto es bastante cercano al encontrado por la granulometría tradicional. Por otro lado, tanto en la granulometría tradicional y el sistema propuesto sólo una piedra fue retenida en el tamiz de 1 pulgada, para su peso, el sistema propuesto cuenta con un error del 9.08%, ya que predice un peso excedido por 1.68 gramos con respecto a su peso real encontrado en la granulometría tradicional. Para el tamiz de $\frac{1}{2}$ de pulgada y $\frac{3}{8}$ de pulgada, se obtuvo un porcentaje de error bastante alto siendo 11.56% y 10.62% respectivamente y finalmente para el peso retenido en el tamiz número 4, un error del 263.58%.

Este caso, el error se debe a la clasificación de las partículas, ya que el peso retenido en cada tamiz será distinto porque la cantidad de piedras retenidas también es diferente.

Tabla 16. Comparación peso retenido Granulometría Tradicional vs Sistema propuesto. Fuente propia.

Tamiz	Granulometría Tradicional	Sistema propuesto	Porcentaje de error
1'	18.5	20.18	9.08%
3/4'	1,459.9	1,465.76	0.40%
1/2'	1,007.8	891.21	11.56%
3/8'	239.5	264.94	10.62%
4	8.1	29.45	263.58%

A pesar de que se encuentran algunas dificultades con respecto a la clasificación de algunas partículas, la gráfica del sistema y de la granulometría tradicional cuentan con la misma tendencia y su curva es muy parecida como se observa en la Figura 34.




Figura 34. Comparación curva granulométrica tradicional vs Sistema propuesto. Fuente propia.

Tanto la línea amarilla correspondiente a la granulometría tradicional como la línea azul correspondiente al sistema propuesto, señalan resultados semejantes con respecto al porcentaje pasante en cada tamiz, ya que dicho porcentaje es calculado con respecto al peso total de la muestra encontrado en cada proceso. Siendo esta gráfica el resultado final en la granulometría de la grava para la fabricación de concreto hidráulico.

5. Conclusiones y trabajos futuros

Para este capítulo se destacan las conclusiones más importantes obtenidas con la realización de este trabajo, consecuentes a cada uno de los objetivos presentes en la investigación. Por último, se proponen algunos trabajos futuros que pueden mejorar los resultados obtenidos en este trabajo y contribuir en el desarrollo de una granulometría de bajo error y en el menor tiempo posible.

5.1. Conclusiones

En el presente trabajo se obtuvo la distribución de tamaños de la grava utilizada para la fabricación de concreto hidráulico mediante procesamiento digital de imágenes y técnicas de aprendizaje automático, con el fin de reducir el tiempo de ejecución manteniendo la precisión en los resultados obtenidos con la granulometría tradicional. En ese orden de ideas, se construyó un prototipo hardware para capturar la imagen del material de estudio. Posteriormente, se elaboró un módulo software para la segmentación de la imagen y seguidamente obtener los datos necesarios de las partículas que componen dicho material. Al mismo tiempo, se creó un módulo de aprendizaje automático, el cual clasifica cada una de las partículas según el tamiz que las retiene y predice su peso, para finalmente obtener la curva de su distribución. Acorde al trabajo realizado, en la presente sección se proponen las siguientes conclusiones de la investigación:

- En el estado actual del conocimiento se evidenció que la mayoría de las aplicaciones para visión de máquina y granulometría se encuentran en la agricultura y medicina. En cuanto a la realización de ensayos en Colombia son muy escasos aquellos donde la granulometría óptica es aplicada en el campo de la geotecnia, por esa razón este trabajo genera una alternativa basada en procesamiento digital de imágenes y aprendizaje automático que permite obtener la distribución de tamaños de un material, en menor tiempo, que puede ser un mecanismo de apoyo para el control de calidad de los materiales de construcción.
- Fue posible evidenciar los problemas más usuales desde el ámbito del hardware en las diferentes aplicaciones de visión de máquina, correspondientes a la organización del material y la configuración luminosa del prototipo. Según la documentación encontrada, existen dos métodos de organización: individualización de cada partícula manualmente o esparcimiento del material sin ningún tipo de manipulación; y múltiples configuraciones luminosas. De esta forma el presente trabajo abstrae los métodos con mayor documentación a favor con el fin de crear un prototipo con las condiciones y directrices más favorables para la captura de fotografías de partículas que permitan la mejor segmentación de las mismas.

- Se evaluó la precisión de distintos algoritmos de aprendizaje automático, teniendo los mejores resultados la técnica de *random forest* tanto para clasificación como para regresión. Todos los algoritmos evaluados fueron seleccionados con base a estudios previos. Aunque en el entrenamiento, los algoritmos seleccionados dieron buen rendimiento, en el momento de evaluar datos nuevos, solo algunos resultados fueron los esperados con respecto a la clasificación, esto por falta de capturar el alto de las partículas, lo que podría mejorar la precisión. Además, existe la posibilidad de analizar otros algoritmos y técnicas. Por ejemplo, si la cantidad de datos recopilados en el conjunto de entrenamiento fuese mayor podría ser evaluado otro enfoque como el de redes neuronales.
- El sistema es competente en el reconocimiento, predicción de peso y clasificación de grava, de forma paralela se cronometró el tiempo exacto en que el sistema fue capaz de fotografiar el material hasta graficar los resultados de la granulometría. De esta forma se confirma que el sistema propuesto reduce el tiempo de ejecución comparado al tiempo que toma hacer una granulometría mediante el uso de tamices.
- Gracias a la evaluación de resultados del sistema propuesto con respecto a los resultados de la granulometría por tamizado, es posible considerar el enfoque aquí propuesto como una alternativa rápida y con resultados aproximados a lo que dictamina el estándar, sin embargo, cabe resaltar que aún no se recomienda como un mecanismo cien por ciento seguro tal como lo puede ser el ensayo mediante tamices.

5.2. Trabajo futuros

En la presente investigación se propuso una alternativa a la granulometría tradicional para obtener la distribución de grava para fabricación de concreto hidráulico con el fin de reducir el tiempo de ejecución para la toma de decisiones. En relación a los resultados obtenidos, se proponen los siguientes trabajos futuros:

- **Utilizar una cámara para captura 3D:** En la granulometría tradicional por tamizado, una partícula puede ser retenida por un tamiz por su posición horizontal, mientras que puede ser pasante por el mismo si su posición es vertical. Esto determina el mismo grado de clasificación para el sistema propuesto, y dentro de los datos solo se cuenta con el ancho y largo, por lo que utilizar una cámara que permita capturar el alto de la partícula ayudará a mejorar la precisión de clasificación, incluso en la predicción del peso para el sistema propuesto.
- **Reemplazar el dispositivo lógico de procesamiento:** Al tratarse de un análisis de figuras irregulares, el dispositivo de procesamiento supone un gasto computacional mayor a que sí se tratara de un análisis de figuras con

formas fijas. Por lo tanto, al no contar con un módulo de procesamiento lógico óptimo los tiempos de ejecución pueden aumentar, esta recomendación se hace con el fin de adecuar el sistema para aplicaciones en tiempo real.

- **Implementar otros tipos de técnicas o algoritmos de aprendizaje automático:** los algoritmos implementados presentan buen rendimiento en la fase de entrenamiento, y solo algunos resultados fueron los esperados cuando se utilizaron nuevos datos, por esa razón cabe la posibilidad de implementar otro tipo de algoritmos como las redes neuronales, aumentando la cantidad de datos ofrecidos en el conjunto de entrenamientos con el fin de aumentar la precisión y obtener mejores resultados de clasificación.
- **Utilizar otras métricas para evaluar los modelos de aprendizaje automático:** la métrica de exactitud y RMSE nos dan un buen indicio en los resultados, pero debido al desbalanceo de los datos en la variable objetivo, se propone la implementación de otro tipo de métricas que permitan disminuir el sesgo producido, logrando obtener mayor información para mejorar la precisión en las pruebas futuras.

6. Bibliografía

- [1] J. I. López Elejalde and S. A. Zuluaga Vanegas, "Análisis granulométrico por medio de fotografía digital en suelos granulares," *Univ. Antioquia*, p. 83, 2014, [Online]. Available: <https://repository.eia.edu.co/handle/11190/2032>.
- [2] I. Papayianni and E. Anastasiou, "Effect of granulometry on cementitious properties of ladle furnace slag," *Cem. Concr. Compos.*, vol. 34, no. 3, pp. 400–407, 2012, doi: 10.1016/j.cemconcomp.2011.11.015.
- [3] J. A. Lizarazo Gómez, C. Serna, and M. Arango, "En La Infraestructura Vial De Corredores Logísticos En Colombia Dynamic Model for Quality Assessment of Logistics Corridor Road Infrastructure in Colombia," *Rev. EIA*, pp. 135–145, 2016, [Online]. Available: <http://www.scielo.org.co/pdf/eia/n25/n25a10.pdf>.
- [4] S. Ferrari, V. Piuri, and F. Scotti, "Image processing for granulometry analysis via neural networks," *CIMSA 2008 - IEEE Conf. Comput. Intell. Meas. Syst. Appl. Proc.*, no. July, pp. 28–32, 2008, doi: 10.1109/CIMSA.2008.4595827.
- [5] I. Marková, E. Mračková, and A. Očkajová, "GRANULOMETRY OF SELECTED WOOD DUST SPECIES OF DUST FROM ORBITAL SANDERS," vol. 61, no. 6, pp. 983–992, 2016.
- [6] S. Ferrari, V. Piuri, and F. Scotti, "Virtual environment for granulometry analysis," *VECIMS 2008 - IEEE Conf. Virtual Environ. Human-Computer Interfaces Meas. Syst. Proc.*, no. July, pp. 156–161, 2008, doi: 10.1109/VECIMS.2008.4592772.
- [7] R. D. Labati, A. Genovese, E. Munoz, V. Piuri, F. Scotti, and G. Sforza, "Improving OSB wood panel production by vision-based systems for granulometric estimation," *2015 IEEE 1st Int. Forum Res. Technol. Soc. Ind. RTSI 2015 - Proc.*, pp. 557–562, 2015, doi: 10.1109/RTSI.2015.7325157.
- [8] A. Laguna *et al.*, "A simple and low cost technique for determining the granulometry of upflow anaerobic sludge blanket reactor sludge," *Water Sci. Technol.*, vol. 40, no. 8, pp. 1–8, 1999, doi: 10.1016/S0273-1223(99)00602-2.
- [9] C. Di Ruberto and L. Putzu, "Accurate blood cells segmentation through intuitionistic fuzzy set threshold," *Proc. - 10th Int. Conf. Signal-Image Technol. Internet-Based Syst. SITIS 2014*, pp. 57–64, 2015, doi: 10.1109/SITIS.2014.43.
- [10] Y. Junhao, Z. Xiubin, and Q. Jie, "A novel optical granulometry algorithm for ore particles," *J. Min. Metall. Sect. B Metall.*, vol. 46, no. 1, pp. 87–95, 2010, doi: 10.2298/JMMB1001087J.
- [11] S. A. De Araújo, J. H. Pessota, and H. Y. Kim, "Beans quality inspection using

- correlation-based granulometry,” *Eng. Appl. Artif. Intell.*, vol. 40, pp. 84–94, 2015, doi: 10.1016/j.engappai.2015.01.004.
- [12] F. Bianconi, F. Di Maria, C. Micale, A. Fernández, and R. W. Harvey, “Grain-size assessment of fine and coarse aggregates through bipolar area morphology,” *Mach. Vis. Appl.*, vol. 26, no. 6, pp. 775–789, 2015, doi: 10.1007/s00138-015-0692-z.
- [13] G. Moreno Chávez, D. Sarocchi, E. Arce Santana, L. Borselli, and L. A. Rodríguez-Sedano, “Using Kinect to analyze pebble to block-sized clasts in sedimentology,” *Comput. Geosci.*, vol. 72, pp. 18–32, 2014, doi: 10.1016/j.cageo.2014.07.008.
- [14] L. Gueguen, P. Soille, and M. Pesaresi, “Differential morphological decomposition segmentation: A multi-scale object based image description,” *Proc. - Int. Conf. Pattern Recognit.*, no. Dmd, pp. 938–941, 2010, doi: 10.1109/ICPR.2010.235.
- [15] D. Sarocchi, L. Borselli, and J. L. Macías, “Construcción de perfiles granulométricos de depósitos piroclásticos por métodos ópticos,” *Rev. Mex. Ciencias Geol.*, vol. 22, no. 3, pp. 371–382, 2005.
- [16] H. Y. Kim, R. H. Maruta, D. R. Huanca, and W. J. Salcedo, “Correlation-based multi-shape granulometry with application in porous silicon nanomaterial characterization,” *J. Porous Mater.*, vol. 20, no. 2, pp. 375–385, 2013, doi: 10.1007/s10934-012-9607-9.
- [17] R. Stoklasa, T. Majtner, and D. Svoboda, “Efficient k-NN based HEp-2 cells classifier,” *Pattern Recognit.*, vol. 47, no. 7, pp. 2409–2418, 2014, doi: 10.1016/j.patcog.2013.09.021.
- [18] M. Jutzeler, A. A. Proussevitch, and S. R. Allen, “Grain-size distribution of volcanoclastic rocks 1: A new technique based on functional stereology,” *J. Volcanol. Geotherm. Res.*, vol. 239–240, pp. 1–11, 2012, doi: 10.1016/j.jvolgeores.2012.05.013.
- [19] G. M. Chávez, D. Sarocchi, E. A. Santana, and L. Borselli, “Optical granulometric analysis of sedimentary deposits by color segmentation-based software: OPTGRAN-CS,” *Comput. Geosci.*, vol. 85, pp. 248–257, 2015, doi: 10.1016/j.cageo.2015.09.007.
- [20] M. Salehizadeh and M. T. Sadeghi, “Size distribution estimation of stone fragments via digital image processing,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6455 LNCS, no. PART 3, pp. 329–338, 2010, doi: 10.1007/978-3-642-17277-9_34.
- [21] G. F. Andriani and N. Walsh, “Physical properties and textural parameters of calcarenitic rocks: Qualitative and quantitative evaluations,” *Eng. Geol.*, vol.

- 67, no. 1–2, pp. 5–15, 2002, doi: 10.1016/S0013-7952(02)00106-0.
- [22] D. Buscombe, “SediNet: a configurable deep learning model for mixed qualitative and quantitative optical granulometry,” *Earth Surf. Process. Landforms*, vol. 45, no. 3, pp. 638–651, 2020, doi: 10.1002/esp.4760.
- [23] G. Kesavaraj and S. Sukumaran, “A study on classification techniques in data mining,” in *2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*, Jul. 2013, pp. 1–7, doi: 10.1109/ICCCNT.2013.6726842.
- [24] Xiaolong Zhu, Huijing Zhao, Yiming Liu, Yipu Zhao, and Hongbin Zha, “Segmentation and classification of range image from an intelligent vehicle in urban environment,” in *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Oct. 2010, pp. 1457–1462, doi: 10.1109/IROS.2010.5652703.
- [25] M. Mohri, A. Rostamizadeh, and A. Talwalkar, *Foundations of Machine Learning*. .
- [26] T. Hastie, R. Tibshirani, and J. Friedman, “Overview of Supervised Learning Chap-2 ;-Part-IIThe Elements of Statistical Learning: Data Mining, Inference and Prediction”, Springer Series in Statistics,” 2009, [Online]. Available: http://www.cse.iitm.ac.in/~vplab/courses/SLT/sup_lrn2.pdf.
- [27] B. Jähne, “Representation of Multidimensional Signals,” *Comput. Vis. Appl.*, pp. 211–272, Jan. 2000, doi: 10.1016/B978-012379777-3/50009-1.
- [28] A. Navada, A. N. Ansari, S. Patil, and B. A. Sonkamble, “Overview of use of decision tree algorithms in machine learning,” *Proc. - 2011 IEEE Control Syst. Grad. Res. Colloquium, ICSGRC 2011*, pp. 37–42, 2011, doi: 10.1109/ICSGRC.2011.5991826.
- [29] B. Ghimire, J. Rogan, V. Galiano, P. Panday, and N. Neeti, “An evaluation of bagging, boosting, and random forests for land-cover classification in Cape Cod, Massachusetts, USA,” *GIScience Remote Sens.*, vol. 49, no. 5, pp. 623–643, 2012, doi: 10.2747/1548-1603.49.5.623.
- [30] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M. Chica-Rivas, “Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines,” *Ore Geol. Rev.*, vol. 71, pp. 804–818, 2015, doi: 10.1016/j.oregeorev.2015.01.001.
- [31] W. Chen, X. Lei, R. Chakraborty, S. Chandra Pal, M. Sahana, and S. Janizadeh, “Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility,” *J. Environ. Manage.*, vol. 284, no. January, p. 112015,

2021, doi: 10.1016/j.jenvman.2021.112015.

- [32] J. Faraway, *"Linear Regression in R"*. 2000.
- [33] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "SciMAT: A new science mapping analysis software tool," *J. Am. Soc. Inf. Sci. Technol.*, vol. 63, no. 8, pp. 1609–1630, Aug. 2012, doi: 10.1002/asi.22688.
- [34] M. A. Martínez, M. J. Cobo, M. Herrera, and E. Herrera-Viedma, "Analyzing the Scientific Evolution of Social Work Using Science Mapping," *Res. Soc. Work Pract.*, vol. 25, no. 2, pp. 257–277, Mar. 2015, doi: 10.1177/1049731514522101.
- [35] M. F. Abad García, I. Abad Pérez, and R. Aleixandre Benavent, "Evaluación de la consistencia en la indización del repertorio Documentación Médica Española," *Rev. española Doc. Científica*, vol. 21, no. 4, pp. 389–401, Dec. 1998, doi: 10.3989/redc.1998.v21.i4.360.
- [36] Y. Chen, "Gray-scale morphological granulometric texture classification," *Opt. Eng.*, vol. 33, no. 8, p. 2713, 1994, doi: 10.1117/12.173552.
- [37] D. Bate, *Photography: The Key Concepts*, no. January. Routledge, 2020.
- [38] R. Wirth and J. Hipp, "CRISP-DM: towards a standard process model for data mining. Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining, 29-39," *Proc. Fourth Int. Conf. Pract. Appl. Knowl. Discov. Data Min.*, no. 24959, pp. 29–39, 2000, [Online]. Available: https://www.researchgate.net/publication/239585378_CRISP-DM_Towards_a_standard_process_model_for_data_mining.
- [39] Z. Ali and Sb. Bhaskar, "Basic statistical tools in research and data analysis," *Indian J. Anaesth.*, vol. 60, no. 9, p. 662, 2016, doi: 10.4103/0019-5049.190623.
- [40] A. Badii, O. P. Guillen, S. Lugo, and J. J. Aguilar Garnica, "Correlación No-Paramétrica y su Aplicación en la Investigaciones Científica Non-Parametric Correlation and Its Application in Scientific Research," *Int. J. Good Conscienc. Agosto*, vol. 9, no. 2, pp. 31–40, 2014.
- [41] S. Abu-Nimeh, D. Nappa, X. Wang, and S. Nair, "A comparison of machine learning techniques for phishing detection," in *Proceedings of the anti-phishing working groups 2nd annual eCrime researchers summit on - eCrime '07*, 2007, pp. 60–69, doi: 10.1145/1299015.1299021.
- [42] M. Yin, J. Wortman Vaughan, and H. Wallach, "Understanding the Effect of Accuracy on Trust in Machine Learning Models," in *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, May 2019, pp. 1–

12, doi: 10.1145/3290605.3300509.

- [43] A. Rácz, D. Bajusz, and K. Héberger, “Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification,” *Molecules*, vol. 26, no. 4, p. 1111, Feb. 2021, doi: 10.3390/molecules26041111.
- [44] C. Bergmeir and J. M. Benítez, “On the use of cross-validation for time series predictor evaluation,” *Inf. Sci. (Ny)*, vol. 191, pp. 192–213, May 2012, doi: 10.1016/j.ins.2011.12.028.
- [45] I. Syarif, A. Prugel-Bennett, and G. Wills, “SVM Parameter Optimization using Grid Search and Genetic Algorithm to Improve Classification Performance,” *TELKOMNIKA (Telecommunication Comput. Electron. Control)*, vol. 14, no. 4, p. 1502, Dec. 2016, doi: 10.12928/telkomnika.v14i4.3956.
- [46] S. P. Neill and R. H. M., *Fundamentals of Ocean Renewable Energy*. Elsevier, 2018.
- [47] R. V. Baños, M. T. Fonseca, and M. R. Álvarez, “Análisis de regresión lineal múltiple con SPSS: un ejemplo práctico.,” *REIRE Rev. d Innovaci i Recer. en Educ.*, vol. 12 (2), pp. 1–10, 2019, doi: 10.1344/reire2019.12.222704.
- [48] J. García, H. Chagolla, and S. Noriega, “Efectos De La Colinealidad En El Modelado De Regresión Y Su Solución,” *Culcyt*, no. 16, pp. 1–6, 2006.
- [49] L. I. Kuncheva, “Ensemble Methods,” in *Combining Pattern Classifiers*, Hoboken, NJ, USA: John Wiley & Sons, Inc., 2014, pp. 186–229.

**ANÁLISIS GRANULOMÉTRICO DE LA GRAVA PARA FABRICACION DE
CONCRETO HIDRÁULICO MEDIANTE PROCESAMIENTO DIGITAL DE
IMÁGENES Y TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**



ANEXOS

**DANIEL AUGUSTO MUÑOZ VIVEROS
JUAN DAVID MUÑOZ VELASCO**

Director

Gustavo Adolfo Ramírez Gonzáles

Codirector

Cristhian Nicolás Figueroa Martínez

Universidad del Cauca
Facultad de Ingeniería Electrónica y Telecomunicaciones
Departamento de Telemática
Popayán, 2022

A Código fuente

Para tener una idea general de cómo se organiza todo el código, se muestra una imagen con la distribución de los archivos:

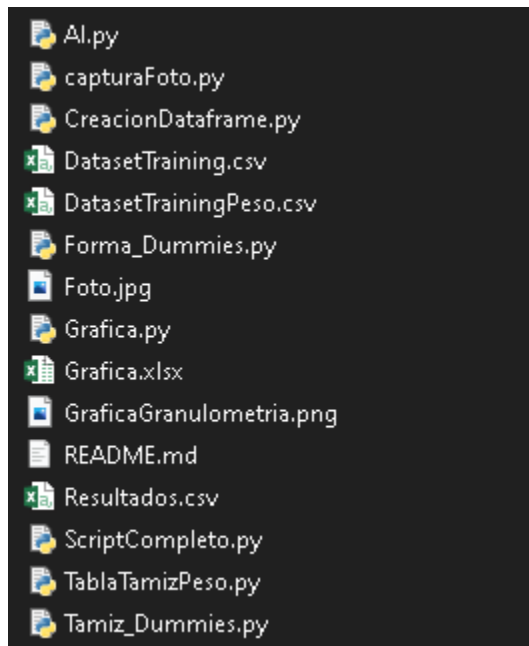


Figura anexos 1. Distribución de archivos. Fuente propia.

Para obtener los archivos del código fuente, es necesario descargar el código fuente desde el repositorio en github.

<https://github.com/16danielvm/AnalisisGranulometricoSistemaPropuesto>

B Montaje prototipo y ejecución del software

Para una mejor explicación del montaje del prototipo hardware se realizó un video el cual se puede observar en el siguiente enlace:

<https://www.youtube.com/watch?v=A2L-K2U6waU>

C Manual de instrucciones








CONSTRUCCIÓN PROTOTIPO PARA EL ANÁLISIS GRANULOMÉTRICO DE LA GRAVA MEDIANTE PROCESAMIENTO DIGITAL DE IMÁGENES Y APRENDIZAJE AUTOMÁTICO.

El sistema de visión artificial propuesto para el análisis granulométrico de la grava del concreto hidráulico se compone de un prototipo hardware para capturar las imágenes del material con un módulo software integrado que implementa tecnologías basadas en el procesamiento de imágenes. También implementa técnicas de aprendizaje automático como mecanismo de clasificación de partículas. Este prototipo hardware se compone de 3 sub-módulos principales, la base luminosa, la base de soporte de dispersión y, la caja de aislamiento de luz y soporte de placa lógica.

Materiales utilizados

Tabla anexos 1. Descripción de componentes para construcción del prototipo. Fuente propia.

Parte	Pieza	Imagen	Cantidad	Medida
A	Tira de luces led		1	5m
B	Placa Raspberry Pi		1	
C	Base de madera		1	80cm x 80cm x 2cm
D	Módulo fotográfico		1	
E	Cubo de madera		4	6.8cm x 6.8cm x 6.8cm
F	Marco de madera		1	Exterior: 80cm x 80cm x 2cm Interior: 62cm x 62cm x 2cm
G	Marco de madera		1	Exterior: 70cm x 70cm x 2cm Interior: 60cm x 60cm x 2cm

H	Placa de vidrio		1	68cm x 68cm x 5mm
I	Lámina de acrílico blanco		1	68cm x 68cm x 2mm
J	Lamina de MDF		4	72.5cm x 82cm x 9mm
N	Lamina de MDF		1	72.5cm x 72.5cm x 9mm
K	Monitor		1	
L	Mouse		1	
M	Teclado		1	

Base luminosa

Para la construcción de la base luminosa, se emplea una cubierta de madera (C) la cual integra en su interior 7 fragmentos de tiras de luces led (A) de 71 cm cada una. Estas tiras se encuentran conectadas eléctricamente en configuración paralela, de tal forma que se conserve la intensidad lumínica a lo largo de la placa.




Figura anexos 2. Sub-Modulo 1 - Base luminosa. Fuente propia

A continuación, en cada esquina se ubican los cuatro cubos de madera(E) con el fin de realizar el soporte para el contenedor del prototipo.

Base de soporte de dispersión

El siguiente sub-módulo se encuentra ubicado sobre la cara superior de la base luminosa. En él, se sobrepone el primer marco de madera(F), seguido por la lámina de vidrio (H) y la lámina de acetato blanco(I). Finalmente, en la parte superior, el segundo marco de madera(G). Esto se hizo con el fin de tener una base sólida y resistente, que permitiera el paso de la luz proveniente de la base luminosa.



Figura anexos 3. Sub-Modulo 2 - Base de soporte de dispersión. Fuente propia.

Caja de aislamiento de luz y soporte de placa lógica

El último sub-módulo fue elaborado con las 5 láminas de MDF (J), creando un contenedor para ser ubicado encima de la secuencia de marcos de madera, con el fin de aislar el material de análisis de todo tipo de luz exterior. Adicionalmente se hizo una apertura en la cara superior de la caja de forma que permitiera la salida del

flex de la cámara (D) para su posterior conexión con el ordenador de placa única (B).



Figura anexos 4. Ubicación módulo fotográfico. Fuente propia.

Finalmente queda construido el prototipo hardware para ser manipulado mediante un monitor (K), mouse (L), y teclado (M), conectados a la placa Raspberry Pi, la cual actúa como capturador e intérprete de los scripts creados en la investigación.



Figura anexos 5. Prototipo hardware

INSTALACIÓN E INICIACIÓN DEL SOFTWARE PARA EL ANÁLISIS GRANULOMÉTRICO DE LA GRAVA MEDIANTE PROCESAMIENTO DIGITAL DE IMÁGENES Y APRENDIZAJE AUTOMÁTICO.

Teniendo en cuenta que se ha hecho correctamente el montaje del prototipo hardware, se procede a la instalación y ejecución del software. Como prerrequisito, es indispensable tener instalado un entorno estable para la ejecución de Python.

Paso 1: Descargar el código fuente desde el repositorio en github.

<https://github.com/16danielvm/AnalisisGranulometricoSistemaPropuesto>

Paso 2: Instalar de dependencias:

En una terminal hacer la instalación de las siguientes librerías Numpy, Pandas, Matplotlib, Scikit-learn.

Paso 3: Ubicar sobre la placa de acetato, el material de construcción (grava) del cual se necesita obtener su curva granulométrica.

Paso 4: Ejecutar el archivo 'capturaFoto.py' el cual activa la cámara del módulo fotográfico para realizar la captura del material y guarda la imagen con el nombre 'Foto.jpg'.

Paso 5: Ejecutar el archivo 'ScriptCompleto.py', el cual leerá la imagen guardada del paso anterior, para clasificar el material y ejecutar el proceso de predicción del peso de cada una de las piedras que lo componen. El cual, al finalizar exporta un archivo Excel con los resultados, y la gráfica de la curva granulométrica del material.

Paso 6: Chequear la carpeta del código fuente, para observar la gráfica y los datos exportados, en el paso anterior.

D. Estimación grado de desarrollo de la tecnología (Nivel TRL)

Se utilizó una herramienta creada por el grupo INNOVATECH de la Universidad Politécnica de Madrid que ha sido adaptada para ayudar a determinar el grado de desarrollo de soluciones tecnológicas innovadoras mediante el uso de la metodología TRL (Technology Readiness Level). Basada en los sistemas de desarrollos por la NASA, el Departamento de Defensa de Estados Unidos, y la Autoridad de Investigación y Desarrollo de Energía del Estado de Nueva York. Donde se respondieron una serie de cuestiones (sí o no), y la herramienta determinó el nivel TRL apropiado para nuestro desarrollo tecnológico concreto.

El resultado arrojado por la herramienta fue de un **Nivel TRL 2**, lo cual significa que, se pueden desarrollar aplicaciones prácticas gracias a que se conocen los principios

básicos de la problemática. Sin embargo, los ejemplos todavía se limitan a estudios analíticos, y la información de apoyo incluyen publicaciones u otras referencias que describan la aplicación considerada.

Grado de desarrollo de tecnología (TRL) - Resultados	
Investigador	Daniel Augusto Muñoz - Juan David Muñoz
Grupo I+D / Centro I+D	Grupo en Ingeniería Telemática
Teléf. de contacto	3112295035 - 3245704526
E-mail	danielvm@unicauca.edu.co - mvjuan@unicauca.
Descripción de la tecnología:	El presente proyecto propone un primer acercamiento para la realización del análisis granulométrico a través de procesando digital de imágenes y aprendizaje automático con la creación de un prototipo hardware funcional y un módulo software.
Nivel TRL conseguido:	2
Nivel desarrollo:	<i>Investigación</i>

Para una mejor visualización de la herramienta y los resultados se puede acceder al siguiente enlace:

https://drive.google.com/drive/folders/1T4j1q_KbGdLu3ghK91dvK7X9V_Gmxqwb?usp=sharing