

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Posgrados**

**Reconstrucción 3D de microestructuras a partir de micrografías usando  
técnicas de visión por computador**

**Proyecto de Titulación**

**Carlos Mateo Jarrín Suango**

**Felipe Grijalva, Ph.D.**

**Director de Trabajo de Titulación**

Trabajo de titulación de posgrado presentado como requisito para la obtención del título de Magíster  
en Inteligencia Artificial

Quito, 13 de Mayo de 2025

# UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

## COLEGIO DE POSGRADOS

### HOJA DE APROBACIÓN DE TRABAJO DE TITULACIÓN

**Reconstrucción 3D de microestructuras a partir de micrografías usando técnicas de visión por computador**

**Carlos Jarrin**

|                                             |                                |
|---------------------------------------------|--------------------------------|
| Nombre del Director del Programa:           | Felipe Grijalva                |
| Título académico:                           | Ph.D. en Ingeniería Eléctrica  |
| Director del programa de:                   | Inteligencia Artificial        |
|                                             |                                |
| Nombre del Decano del colegio Académico:    | Eduardo Alba                   |
| Título académico:                           | Doctor en Ciencias Matemáticas |
| Decano del Colegio:                         | Ciencias e Ingenierías         |
|                                             |                                |
| Nombre del Decano del Colegio de Posgrados: | Dario Niebieskikwiat           |
| Título académico:                           | Doctor en Física               |

**Quito, 13 mayo 2025**

## © DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombre del estudiante: Carlos Jarrin

Código de estudiante: 00339508

C.I.: 1750225425

Lugar y fecha: Quito, 13 de Mayo de 2025.

## ACLARACIÓN PARA PUBLICACIÓN

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

## UNPUBLISHED DOCUMENT

**Note:** The following graduation project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

## DEDICATORIA

A mis abuelos, Carlos Jarrín y Rosa Suango, por su amor incondicional, por cuidarme siempre con ternura, paciencia y sabiduría. Su presencia ha sido un refugio y su ejemplo una guía silenciosa en los momentos más importantes de mi vida.

A mis tías, Patricia y Sandra, por estar a mi lado con palabras de aliento, con apoyo sincero y constante, incluso cuando el camino se volvía incierto. Gracias por creer en mí incluso cuando yo dudaba.

Y a mi madre, Mónica, quien con su fuerza, cariño y ejemplo me ha enseñado a no rendirme, a seguir adelante con firmeza y humildad. Su guía ha sido luz en mi formación, no solo académica, sino también como persona.

A todos ustedes, les dedico este logro que es también suyo.

## AGRADECIMIENTOS

De manera especial, agradezco a los miembros del instituto que contribuyeron activamente en las diferentes etapas del trabajo: al Ph.D., Alfredo Valarezo Garcés, por su guía constante y orientación técnica; al Ph.D., Felipe Grijalva Arévalo, por su colaboración en el análisis de datos y la aplicación de técnicas de inteligencia artificial; y al M.Sc., Marco León, por su valioso aporte en la evaluación experimental y la simulación 3D.

Asimismo, extiendo mi gratitud a todas las personas e instituciones que colaboraron en la generación, recolección y análisis de los datos, y que hicieron posible la realización de este trabajo.

## RESUMEN

Actualmente, el campo de los materiales se encuentra profundamente vinculado al uso de tecnologías avanzadas, las cuales suelen implicar altos costos y la necesidad de contar con personal altamente especializado. En este contexto, el desarrollo de simulaciones precisas para aplicaciones científicas e industriales requiere tanto de recursos tecnológicos como humanos.

El presente proyecto tiene como objetivo modernizar estos procesos mediante la implementación de técnicas de inteligencia artificial para la reconstrucción tridimensional de microestructuras. Para ello, se utilizaron imágenes en 2D obtenidas de manera secuencial a través de un microscopio óptico, empleando el método de rebanado (slicing en inglés). En total, se recopilieron 120 imágenes correspondientes a grafito nodular, una característica distintiva del hierro fundido.

A partir de estas imágenes, se llevó a cabo una reconstrucción tridimensional de la microestructura, evaluando distintas técnicas de segmentación mediante visión por computadora. El método que arrojó los mejores resultados fue clustering, ya que permitió preservar todas las características necesarias para una representación fiel en 3D. Aunque otros métodos mostraron resultados consistentes, el enfoque de agrupamiento utilizando k-means destacó por mantener la integridad de las formas y estructuras del grafito.

El modelo generado cumplió con los requerimientos de alineación (Shi-Tomasi y Border Edge Recognition), y se validó mediante pruebas con durómetro. La reconstrucción no presentó anomalías ni desviaciones en los ángulos de la pirámide, y los nódulos de grafito conservaron su secuencia espacial, lo cual fue corroborado visualmente a través de programas especializados (MeshLab).

**Palabras clave:** 3D reconstruction, Nodular graphite, Cast iron, Computer vision, Image segmentation, Clustering, K-means, Artificial intelligence, Microstructure analysis, Optical microscopy.

## ABSTRACT

Currently, the field of materials science is deeply linked to the use of advanced technologies, which often involve high costs and the need for highly specialized personnel. In this context, the development of accurate simulations for scientific and industrial applications requires both technological and human resources. The present project aims to modernize these processes through the implementation of artificial intelligence techniques for the three-dimensional reconstruction of microstructures. To achieve this, 2D images were sequentially captured using an optical microscope, employing the slicing method. A total of 120 images corresponding to nodular graphite, a distinctive feature of cast iron, were collected. Based on these images, a three-dimensional reconstruction of the microstructure was carried out, evaluating different segmentation techniques using computer vision. The method that yielded the best results was clustering, as it preserved all the necessary characteristics for an accurate 3D representation. Although other methods produced consistent results, the clustering approach using k-means stood out for maintaining the integrity of the shapes and structures of the graphite. The generated model met the alignment requirements (Shi-Tomasi and Border Edge Recognition) and was validated through tests using a durometer. The reconstruction showed no anomalies or deviations in the angles of the pyramid, and the graphite nodules preserved their spatial sequence, which was visually confirmed through specialized programs (MeshLab).

**Key words:** 3D reconstruction, Nodular graphite, Cast iron, Computer vision, Image segmentation, Clustering, K-means, Artificial intelligence, Microstructure analysis, Optical microscopy.

# TABLA DE CONTENIDO

|            |                                                                           |           |
|------------|---------------------------------------------------------------------------|-----------|
| <b>I</b>   | <b>Introduccion</b>                                                       | <b>11</b> |
| <b>II</b>  | <b>Métodos</b>                                                            | <b>11</b> |
| II-A       | Segmentación de imágenes . . . . .                                        | 12        |
| II-A1      | Visión por computador . . . . .                                           | 12        |
| II-A2      | Aprendizaje no Supervisado . . . . .                                      | 12        |
| II-A3      | Aprendizaje Profundo: SAM 2 (modelo pre-entrenado) . . . . .              | 13        |
| II-B       | Alineación de imágenes . . . . .                                          | 14        |
| II-C       | Segmentación en 3D, Gráficos por Computadora en 3D y Reconstrucción en 3D | 15        |
| <b>III</b> | <b>Resultados</b>                                                         | <b>15</b> |
| <b>IV</b>  | <b>Conclusion</b>                                                         | <b>15</b> |
| <b>V</b>   | <b>Trabajos a Futuro</b>                                                  | <b>16</b> |
|            | <b>Appendix A: Repositorio</b>                                            | <b>16</b> |
|            | <b>References</b>                                                         | <b>17</b> |

## ÍNDICE DE FIGURAS

|    |                                                                                                                                                                                           |    |
|----|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 1  | Muestra las 3 formas de segmentación utilizando técnicas avanzadas de visión artificial. Aprendizaje supervisado, Vision por computadora y por ultimo modelo pre entrenado SAM 2. . . . . | 12 |
| 2  | Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando CV, por último ejemplo de hierro gris. . . . .                                                          | 12 |
| 3  | Gráfico que indica la distribución de cada uno de las formas de segmentación por CV, a la izquierda el modelo nodular y a la derecha el hierro gris. . . . .                              | 12 |
| 4  | Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando Aprendizaje no Supervisado, por último ejemplo de hierro gris. . . . .                                  | 12 |
| 5  | Gráfico que indica la distribución de cada uno de las formas de segmentación por Aprendizaje no Supervisado, a la izquierda el modelo nodular y a la derecha el hierro gris. . . . .      | 13 |
| 6  | Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando SAM 2, por último ejemplo de hierro gris. . . . .                                                       | 13 |
| 7  | Gráfico que indica la distribución de cada uno de las formas de segmentación usando SAM 2, a la izquierda el modelo nodular y a la derecha el hierro gris. . . . .                        | 14 |
| 8  | Segmentación del indentador, líneas de Hough, algoritmo Shi-Tomasi y diagonales . . .                                                                                                     | 14 |
| 9  | Alineamiento en función del prisma para asegurar una reconstrucción fiduciaria. . . . .                                                                                                   | 14 |
| 10 | Imagen correspondiente a la geometría del indentador Vickers vista lateral. . . . .                                                                                                       | 14 |
| 11 | Comparación de la imagen original, el resultado del agrupamiento de grafito y su conversión a escala de grises. . . . .                                                                   | 15 |
| 12 | Reconstrucción en 3D para el grafito nodular. . . . .                                                                                                                                     | 15 |
| 13 | Comparación de errores según las diferentes técnicas de segmentación. . . . .                                                                                                             | 15 |

# Reconstrucción 3D de microestructuras a partir de micrografías usando técnicas de visión por computador

Carlos Jarrin, *Universidad San Francisco de Quito, USFQ*, Felipe Grijalva, *Universidad San Francisco de Quito, USFQ*,

**Abstract**—Currently, the field of materials science is deeply linked to the use of advanced technologies, which often involve high costs and the need for highly specialized personnel. In this context, the development of accurate simulations for scientific and industrial applications requires both technological and human resources. The present project aims to modernize these processes through the implementation of artificial intelligence techniques for the three-dimensional reconstruction of microstructures. To achieve this, 2D images were sequentially captured using an optical microscope, employing the slicing method. A total of 120 images corresponding to nodular graphite, a distinctive feature of cast iron, were collected. Based on these images, a three-dimensional reconstruction of the microstructure was carried out, evaluating different segmentation techniques using computer vision. The method that yielded the best results was clustering, as it preserved all the necessary characteristics for an accurate 3D representation. Although other methods produced consistent results, the clustering approach using k-means stood out for maintaining the integrity of the shapes and structures of the graphite. The generated model met the alignment requirements (Shi-Tomasi and Border Edge Recognition) and was validated through tests using a durometer. The reconstruction showed no anomalies or deviations in the angles of the pyramid, and the graphite nodules preserved their spatial sequence, which was visually confirmed through specialized programs (MeshLab).

**Index Terms**—3D reconstruction, Nodular graphite, Cast iron, Computer vision, Image segmentation, Clustering, K-means, Artificial intelligence, Microstructure analysis, Optical microscopy.

## I. INTRODUCCION

LA reconstrucción en 3D consiste en obtener una microestructura tridimensional (3D) a partir de imágenes bidimensionales (2D), permitiendo la simulación de la dureza de un material mediante ensayos experimentales. Para este propósito, se emplearon diversas técnicas de inteligencia artificial, incluyendo aprendizaje profundo, aprendizaje no supervisado y visión por computadora. Es importante destacar que modelar microestructuras no solo facilita el estudio de la dureza, sino que también permite generar simulaciones de distintos tipos, esenciales para establecer y predecir propiedades mecánicas, térmicas y estructurales de los materiales. [1], [2]

La importancia de obtener el modelo tridimensional para simulación computacional es un gran avance puesto que se puede simular por medio de software especializado en elementos finitos el comportamiento físico de dichas estructuras.

Los materiales de los cuales se obtuvo las muestras son de hierro fundido y hierro gris o fundición gris. El hierro fundido es una aleación hierro-carbono superior al 4% característico por mostrar en la micrografía una forma esferoidal particular de carbono alojados de manera heterogénea en una matriz de hierro. Por otro lado, el hierro gris mantiene la estructura en forma de hojuelas o laminas de grafito a lo largo de la matriz.

Dado estas dos muestras totalmente diferentes, pero con similitud al momento de segmentación había una manera muy intuitiva para realizar la reconstrucción 3D, era que se alineaba manualmente reconstruyendo cada imagen, sin embargo, el reto de alineación bidimensional también representaba un reto por lo cual es importante remarcar que se realizó una indentación en cada muestra para poder saber la orientación y profundidad a la que se debería ubicar dicha imagen.

Las imágenes son tomadas de una muestra de dicho material el cual para obtener la siguiente capa utilizamos una técnica de pulido donde se reduce una micra en profundidad, de esta forma se obtuvo 120 imágenes/micrografías para el hierro nodular y 50 imágenes para el hierro gris por medio del microscopio óptico.

## II. MÉTODOS

Inicialmente, se recopiló un conjunto de datos de imágenes relevantes (conjunto de datos). Posteriormente, se generaron máscaras con ayuda de técnicas tradicionales de visión por computadora por medio de software como IMAGEJ y Photoshop. Este procedimiento fue llevado a cabo por varios investigadores a lo largo de algunos meses. Las máscaras permiten comparar los resultados de segmentación obtenidos, evaluar el accuracy de las técnicas de segmentación con IA, así como definir áreas de interés [3], [4], [5], [6].

A continuación, un ejemplo de la misma imagen aplicando 3 formas de segmentación distintas:




Figure 1. Muestra las 3 formas de segmentación utilizando técnicas avanzadas de visión artificial. Aprendizaje supervisado, Vision por computadora y por ultimo modelo pre entrenado SAM 2.

### A. Segmentación de imágenes

Se probaron tres enfoques distintos para la segmentación de imágenes:

1) *Visión por computador:* Se utilizó la técnica del threshold binary con Otsu para establecer un proceso de binarizado adecuado según la imagen [7], [8]. Se




Figure 2. Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando CV, por último ejemplo de hierro gris.

aplicaron operaciones morfológicas para empezar con la preparación de la segmentación. Se utilizó erosión & dilatación en iteraciones de 2 veces con un kernel de 3x3 para eliminar el ruido de la imágenes todas las operaciones morfológicas [9]. Se realizó una operación de distance transform en una imagen de soporte para localizar el foreground y background del objetivo de segmentación. Tener el foreground permitió identificar los edges del grafito, lo que permitió emplear watershed [10]. Watershed es un algoritmo de segmentación de imágenes cuyo objetivo principal es separar objetos

superpuestos o áreas de interés dentro de una imagen [11], [12], [13]. Se empleó una imagen de soporte para trabajar sobre el foreground con un dilation en iteración de 10 veces.




Figure 3. Gráfico que indica la distribución de cada uno de las formas de segmentación por CV, a la izquierda el modelo nodular y a la derecha el hierro gris.




Figure 4. Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando Aprendizaje no Supervisado, por último ejemplo de hierro gris.

2) *Aprendizaje no Supervisado*: Para segmentar las imágenes con base en características de color, se aplicó el algoritmo de clustering K-means, estableciendo un número de grupos  $k=3$ . Este valor fue determinado empíricamente, pero también puede ser optimizado utilizando el método del codo (elbow method), una técnica que consiste en evaluar la suma de los errores cuadráticos dentro de los grupos (inertia) para diferentes valores de  $k$ , y seleccionar aquel en el que la mejora marginal comienza a disminuir abruptamente. Este punto de inflexión sugiere un balance óptimo entre la complejidad del modelo y la representatividad de los grupos encontrados. Previo a la aplicación del algoritmo K-means, fue necesario transformar la estructura de la imagen. Dado que una imagen en formato RGB contiene tres canales de color —rojo, verde y azul—, cada píxel puede ser representado como un vector tridimensional en el espacio de color. Para que el algoritmo pudiera operar, la imagen fue

reorganizada (reshaped) desde una matriz tridimensional [alto×ancho×3] a una matriz bidimensional de tamaño [número de píxeles×3], donde cada fila representa un píxel y cada columna, la intensidad de uno de los canales de color. Esta reorganización permitió que cada píxel fuera tratado como un punto en un espacio tridimensional definido por sus componentes RGB. La ventaja de esta representación radica en que los colores similares se agrupan naturalmente en regiones específicas dentro de este espacio tridimensional. Por lo tanto, mediante K-means, fue posible identificar patrones de color y clasificar los píxeles en tres grupos distintos, cada uno correspondiente a un color promedio representativo de su respectivo clúster. Esta técnica no solo facilita la segmentación de regiones con propiedades cromáticas similares, sino que también proporciona una base para reducir la complejidad de la imagen sin pérdida significativa de información visual. Además, es posible visualizar los datos en un espacio tridimensional RGB para comprender mejor la distribución de colores en la imagen. Esta visualización permite observar cómo se concentran los píxeles en torno a ciertos vectores de color y cómo el algoritmo K-means traza las fronteras entre los clústeres. Dichas visualizaciones son especialmente útiles en el análisis exploratorio previo a la segmentación, ya que ofrecen una comprensión intuitiva de la diversidad cromática de la imagen [14]. Se emplearon diversas librerías para facilitar el procesamiento de datos, por ejemplo OPEN CV, Scikit-Learn que tienen todos estos algoritmos implementados.




Figure 5. Gráfico que indica la distribución de cada uno de las formas de segmentación por Aprendizaje no Supervisado, a la izquierda el modelo nodular y a la derecha el hierro gris.

*3) Aprendizaje Profundo: SAM 2 (modelo pre-entrenado):* SAM 2 requiere unos parámetros mínimos de ajuste para equilibrar precisión, eficiencia computacional y robustez en la segmentación. A continuación, se describen los principales hiperparámetros utilizados: El parámetro `points_per_side` se establece en 64, lo que indica la cantidad de puntos que se muestrean uniformemente a lo largo de cada lado de la imagen para generar prompts de segmentación. Esto define la densidad con la que el modelo explora posibles regiones de interés. Asociado a ello, `points_per_batch` se configura en 128, lo que determina cuántos puntos se procesan simultáneamente en cada lote durante la inferencia, optimizando el uso




Figure 6. Primera y segunda franja muestra ejemplo de segmentación de hierro nodular usando SAM 2, por último ejemplo de hierro gris.

de memoria y la velocidad de procesamiento. Para asegurar la calidad de las máscaras generadas, se aplica un umbral de intersección sobre unión (`pred_iou_thresh`) de 0.7, que filtra las máscaras con baja confianza según la predicción del modelo. Este umbral actúa como una medida de similitud entre la predicción y una referencia interna del modelo. Además, se incorpora un criterio de estabilidad mediante `stability_score_thresh`, fijado en 0.97, que permite descartar máscaras susceptibles a pequeñas perturbaciones en el prompt. Este umbral se ajusta mediante `stability_score_offset`, establecido en 0.5, que define la magnitud de la perturbación usada para calcular dicho puntaje de estabilidad. Para mejorar la segmentación de objetos pequeños o con detalles finos, se aplica una estrategia de recorte (`crop_n_layers=1`), que permite evaluar la imagen en diferentes escalas. Sin embargo, para mantener la eficiencia, sólo se utiliza una capa de recorte adicional. Al aplicar recortes, el modelo también reduce la densidad de puntos proporcionalmente a través del parámetro `crop_n_points_downscale_factor`, fijado en 2, disminuyendo así la carga computacional sin sacrificar demasiada precisión.

La eliminación de máscaras redundantes se controla mediante el parámetro `box_nms_thresh`, con un valor de 0.7. Este umbral se utiliza en la técnica de supresión no máxima (Non-Maximum Suppression, NMS) para descartar máscaras que se solapan en exceso, reteniendo únicamente aquellas más representativas. Por otro lado, se establece un umbral mínimo de área para las máscaras aceptadas (`min_mask_region_area=25.0`), lo que permite filtrar aquellas demasiado pequeñas que podrían corresponder a ruido o detalles irrelevantes. Finalmente, se activa la opción `use_m2m=True`, que habilita el modo many-to-many de SAM 2. Esta funcionalidad permite generar múltiples máscaras de forma paralela y coherente, mejorando tanto la eficiencia como la cobertura de objetos dentro de la imagen.




Figure 7. Gráfico que indica la distribución de cada uno de las formas de segmentación usando SAM 2, a la izquierda el modelo nodular y a la derecha el hierro gris.

### B. Alineación de imágenes

Se emplearon técnicas tradicionales de visión por computador con el objetivo de segmentar y analizar el cuadrado de indentación presente en las muestras. En primer lugar, se utilizó la Transformada de Hough, una herramienta eficaz para la detección de líneas rectas, lo que permitió identificar con precisión los bordes del cuadrado. A continuación, se aplicó el algoritmo de detección de esquinas de Shi-Tomasi, el cual facilitó la localización exacta de las diagonales del cuadrado. Estas diagonales sirvieron como referencias clave para la alineación espacial de las imágenes, permitiendo una orientación uniforme a lo largo de toda la secuencia de micrografías.




Figure 8. Segmentación del indentador, líneas de Hough, algoritmo Shi-Tomasi y diagonales .




Figure 9. Alineamiento en función del prisma para asegurar una reconstrucción fiduciaria.

Una vez alineadas las imágenes y definido el cuadrado de indentación en cada una de ellas, fue posible determinar con mayor precisión la profundidad relativa a la que corresponde cada micrografía utilizando principios de geometría asociados a la forma del indentador. Esta información permitió ubicar espacialmente cada imagen

a lo largo del eje z, lo cual es fundamental para lograr una reconstrucción tridimensional coherente y precisa del volumen de la muestra.

Para fines prácticos, se seleccionó un área de interés de aproximadamente 800 x 500 píxeles, correspondiente a la región de la muestra con información relevante. Dado que la técnica de obtención de las imágenes consistía en realizar cortes sucesivos mediante un proceso de pulido, eliminando aproximadamente una micra de material por cada corte, se asumió que la resolución espacial en profundidad era equivalente a la resolución lateral. Es decir, un píxel en la imagen representaba una micra tanto en el plano xy, tanto como en el eje z. Esta suposición permitió utilizar la escala de píxeles no solo para definir el área de interés en el plano de la imagen, sino también para calcular con precisión la profundidad relativa de cada micrografía en el volumen tridimensional.

Durante este proceso de análisis, se identificaron inconsistencias en algunas de las imágenes adquiridas. En particular, tres micrografías debieron ser descartadas del conjunto final debido a que se encontraban mal posicionadas en términos de profundidad. Por ejemplo, se detectó que una imagen correspondiente a la posición 11 presentaba una diagonal significativamente menor en comparación con las imágenes de las posiciones 10 y 9. Esta anomalía indicaba una discontinuidad en la progresión geométrica esperada, lo cual sugería que la imagen no representaba correctamente su nivel de profundidad real. En lugar de contribuir al modelo tridimensional, generaba confusión y distorsión en la representación volumétrica.

La causa de estas inconsistencias puede atribuirse a errores durante la captura de las micrografías, particularmente a la posible inclinación de la muestra al momento de ser colocada bajo el microscopio. Tal inclinación habría provocado una ligera curvatura en la superficie durante el proceso de pulido, lo que afectó la uniformidad del corte y, por consiguiente, la fidelidad de la imagen adquirida. Esta situación resalta la importancia de mantener una rigurosa preparación de la muestra y un control estricto de los procedimientos experimentales, especialmente cuando se requiere un alto nivel de precisión en la reconstrucción tridimensional de materiales mediante imágenes seriadas.




Figure 10. Imagen correspondiente a la geometría del indentador Vickers vista lateral.

$$\bar{l}_n = \frac{l_n + \frac{d_n}{\sqrt{2}}}{2}$$

$$h_n = \frac{\bar{l}_n - \bar{l}_{n-1}}{2 \tan(68^\circ)}$$

Fórmulas las cuales se determinaron a partir de la geometría del indentador para establecer la posición del mismo.

### C. Segmentación en 3D, Gráficos por Computadora en 3D y Reconstrucción en 3D

Una vez elegida la técnica de IA más adecuada se procedió a segmentar toda la imagen de 1080x1250 px. El objetivo de esta etapa fue segmentar sin perder información, pese a que se mantengan ciertos defectos. En este punto no se contaba con una máscara para comparar debido a que el corte realizado anteriormente no considera la marca del indentador. Motivo por el cual, se corroboró con el ensayo Vickers para valorar la estimación de dureza. Usando un kernel en 3 dimensiones de tamaño 5x5x5 con lo que se obtuvo los siguientes resultados.




Figure 11. Comparación de la imagen original, el resultado del agrupamiento de grafito y su conversión a escala de grises.

El postprocesamiento se realizó con la utilización de varios software. Para la visualización y tratamiento del archivo vtk se utilizó Paraview y Meshlab con lo cual se pueden obtener archivos para la simulación. Además, el software Fusion permite el manejo de archivos obj en inp o geometrías sólidas para la simulación.




Figure 12. Reconstrucción en 3D para el grafito nodular.

## III. RESULTADOS

Tras la comparación de resultados, se determinó que la mejor técnica para la segmentación de datos era el clustering, dado que preservaba mejor las características de los segmentos de interés [15], [16]. Sin embargo, esta técnica tendía a aceptar segmentos muy pequeños como válidos, estos podían corregirse aplicando visión por computadora en 3D. Esto puede ser corregido al correr una técnica de computer vision en 3D, esta técnica ya ha sido implementada en otras investigaciones [17], [18]. No se utilizó el entrenamiento supervisado sin usar redes neuronales pre entrenadas porque la información perdida a lo largo de la predicción al reconstruir la imagen recortada (crop) era amplia. En comparación con el accuracy mayor al 90% en sus imágenes del clustering, motivo por el cual fue la técnica seleccionada.




Figure 13. Comparación de errores según las diferentes técnicas de segmentación.

## IV. CONCLUSION

El presente trabajo demuestra que la aplicación de técnicas de inteligencia artificial en la reconstrucción tridimensional de microestructuras representa una alternativa eficiente y precisa frente a los métodos tradicionales, los cuales suelen requerir un elevado consumo de tiempo, recursos computacionales y esfuerzo humano especializado. A partir de imágenes bidimensionales obtenidas mediante microscopía óptica y utilizando técnicas de preparación como el pulido mecánico, fue posible reconstruir con alta fidelidad la estructura espacial de los nódulos de grafito presentes en muestras de hierro fundido.

El proceso incluyó el uso de algoritmos de segmentación como K-means clustering, los cuales permitieron identificar y agrupar píxeles de características similares, facilitando la extracción precisa de las regiones de interés. Gracias a esta segmentación y a una adecuada alineación de las micrografías, se logró una representación tridimensional coherente que respeta la disposición real de los nódulos dentro del volumen del material. La validez del modelo se evidencia en la correcta identificación de estructuras

clave, como la pirámide de indentación, lo cual corrobora la veracidad y precisión de la reconstrucción generada.

Este enfoque no solo facilita la simulación computacional de propiedades mecánicas como la dureza, sino que también abre nuevas perspectivas en la predicción del comportamiento estructural del material y en el diseño de aleaciones avanzadas con microestructuras optimizadas. La metodología aquí propuesta establece una base sólida para el desarrollo de herramientas automatizadas de caracterización tridimensional, lo cual representa un avance significativo para la ciencia de materiales y su aplicación en entornos industriales, al optimizar tanto los tiempos de análisis como los costos asociados a la caracterización experimental tradicional.

La adquisición adecuada de imágenes constituye un aspecto fundamental dentro del proceso de caracterización microestructural, ya que la calidad y representatividad de las micrografías incide directamente en la validez de los resultados obtenidos durante las etapas de segmentación y reconstrucción. Si una imagen no refleja de manera fiel la estructura interna del material, la información que se puede extraer de ella será limitada o incluso errónea.

En el caso específico del hierro gris, se identificó que las imágenes capturadas no son completamente representativas de su microestructura característica, lo que sugiere la necesidad de repetir el proceso de adquisición para asegurar que los datos utilizados en los análisis reflejen adecuadamente la realidad del material. A pesar de esta limitación, se continuó con el desarrollo metodológico tomando en cuenta estas consideraciones, y se evaluó el rendimiento de distintos métodos de segmentación.

Entre los algoritmos considerados, el método de clustering K-means demostró ser el más eficaz para este tipo de análisis, permitiendo una segmentación precisa de las fases presentes en la microestructura. Se exploraron diferentes valores de  $k$  con el objetivo de identificar el número óptimo de grupos que mejor representara las regiones de interés en la imagen. Esta estrategia permitió mejorar la calidad de la segmentación, incluso frente a imágenes con deficiencias en la representación del material, sentando así una base metodológica sólida para estudios futuros.

## V. TRABAJOS A FUTURO

A partir de los resultados obtenidos en el presente estudio, se plantean dos líneas principales de investigación que pueden fortalecer y ampliar los alcances del análisis microestructural mediante técnicas computacionales:

1. Entrenamiento de un modelo de inteligencia artificial para segmentación 3D a partir de un stack de imágenes 2D.

Una forma de visualizar el avance obtenido hasta el momento es proyectarlo hacia el desarrollo y entrenamiento

de un modelo de segmentación tridimensional basado en redes neuronales. Este modelo estaría diseñado para procesar directamente el stack de imágenes bidimensionales obtenidas a través de microscopía óptica, con el objetivo de reconstruir automáticamente una representación 3D precisa de la microestructura del material. El enfoque podría beneficiarse del uso de arquitecturas como CNN 3D o redes basadas en transformers espaciales. La ventaja de este enfoque radica en que, una vez entrenado con datos anotados o segmentados previamente, el modelo podría generalizar a nuevas muestras sin necesidad de intervención manual, automatizando completamente el proceso de reconstrucción tridimensional. Para entrenar este tipo de red, sería necesario preparar un conjunto de datos con imágenes segmentadas en 2D, sin embargo, cabe recalcar que solo existe un modelo de reconstruido, lo cual compromete este entrenamiento. Existe la posibilidad de aumentar los datos con técnicas como girar las muestras, posicionarles de otra forma, hacer recortes, etc. Esta línea de trabajo no solo permitiría mejorar la precisión y velocidad de la reconstrucción, sino también escalar el análisis a mayores volúmenes de datos.

2. Generación de una distribución estadística de nódulos de grafito a partir del modelo de segmentación actual.

La segunda línea de investigación se enfoca en aplicar los resultados del modelo actual de segmentación para realizar un análisis estadístico exhaustivo de la distribución, morfología y densidad de los nódulos de grafito presentes en el material. Con la segmentación ya obtenida, es posible extraer métricas geométricas relevantes como el área, perímetro, circularidad, orientación y volumen estimado de cada nódulo. A partir de estas métricas, se puede construir una distribución probabilística de las características morfológicas, lo cual resultaría clave para correlacionar la microestructura con las propiedades mecánicas del material, tales como la dureza, resistencia a la tracción y comportamiento frente a la fractura. Además, esta información puede alimentar modelos de simulación por elementos finitos más realistas, donde la heterogeneidad del material a nivel microestructural se considere explícitamente. A largo plazo, esta línea de trabajo permitiría incluso generar modelos sintéticos o simulados de microestructuras, mediante técnicas de generación de datos como modelos generativos (GANs) los cuales podrían ser útiles para entrenar modelos de aprendizaje profundo sin necesidad de adquirir datos experimentales costosos o complejos.

## APPENDIX A REPOSITORIO

Repositorio en github:

[https://github.com/carlosmaja/3d\\_project.git](https://github.com/carlosmaja/3d_project.git)

## REFERENCES

- [1] D. J. Rezende, S. M. A. Eslami, S. Mohamed, P. Battaglia, M. Jaderberg, and N. Heess, "Unsupervised learning of 3d structure from images," *Advances in Neural Information Processing Systems*, vol. 29, pp. 5003–5011, 7 2016. [Online]. Available: <https://arxiv.org/abs/1607.00662v2>
- [2] W. Yu, P. Wang, W. Du, and X. Shen, "Research on visual modeling technology of 3d mining engineering based on deep learning," *Academic Journal of Science and Technology*, vol. 2, pp. 118–121, 8 2022. [Online]. Available: <https://drpress.org/ojs/index.php/ajst/article/view/1297>
- [3] A. Adam, K. Karantzos, L. Grammatikopoulos, and T. Sattler, "Has anything changed? 3d change detection by 2d segmentation masks," 12 2023. [Online]. Available: <https://arxiv.org/abs/2312.01148v1>
- [4] Z. Gao, L. Li, L. Jiao, F. Liu, X. Liu, W. Ma, Y. Guo, and S. Yang, "Fast and efficient: Mask neural fields for 3d scene segmentation," *arXiv preprint arXiv:2407.01220*, 7 2024. [Online]. Available: <https://arxiv.org/abs/2407.01220v3>
- [5] J. Joseph, B. Amrutur, and S. Bhatnagar, "Gradient-driven 3d segmentation and affordance transfer in gaussian splatting using 2d masks," *arXiv preprint arXiv:2409.11681*, 9 2024. [Online]. Available: <https://arxiv.org/abs/2409.11681v1>
- [6] A. Mora, A. Mendez, and R. Barber, "Evaluating techniques for accurate 3d object model extraction through image-based deep learning object detection and point cloud segmentation," in *2023 European Conference on Mobile Robots (ECMR)*. IEEE, 9 2023, pp. 1–7. [Online]. Available: <https://ieeexplore.ieee.org/document/10256418/>
- [7] D. N. Bhargava, A. kumawat, and D. R. Bhargava, "Threshold and binarization for document image analysis using otsu's algorithm," *International Journal of Computer Trends and Technology*, vol. 17, pp. 272–275, 11 2014.
- [8] C. Vertan, C. Florea, L. Florea, and M. S. Badea, "Reusing the otsu threshold beyond segmentation," *ISSCS 2017 - International Symposium on Signals, Circuits and Systems*, 9 2017.
- [9] A. Narayanan, "Fast binary dilation/erosion algorithm using kernel subdivision," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 3852 LNCS, pp. 335–342, 2006. [Online]. Available: [https://link.springer.com/chapter/10.1007/11612704\\_34](https://link.springer.com/chapter/10.1007/11612704_34)
- [10] D. Nadadur and R. M. Haralick, "Recursive binary dilation and erosion using digital line structuring elements in arbitrary orientations," *IEEE Transactions on Image Processing*, vol. 9, pp. 749–759, 2000. [Online]. Available: [https://www.researchgate.net/publication/5597669\\_Recursive\\_binary\\_dilation\\_and\\_erosion\\_using\\_digital\\_line\\_structuring\\_elements\\_in\\_arbitrary\\_orientations](https://www.researchgate.net/publication/5597669_Recursive_binary_dilation_and_erosion_using_digital_line_structuring_elements_in_arbitrary_orientations)
- [11] T. W. Pinto, M. A. D. Carvalho, D. C. Pedronette, and P. S. Martins, "Image segmentation through combined methods: Watershed transform, unsupervised distance learning and normalized cut," *Proceedings of the IEEE Southwest Symposium on Image Analysis and Interpretation*, pp. 153–156, 2014.
- [12] M. Sharma and S. Verma, "Implementation of watershed based image segmentation algorithm using distance transform for grid computing," *INTERNATIONAL JOURNAL OF COMPUTERS TECHNOLOGY*, vol. 10, pp. 1715–1719, 8 2013. [Online]. Available: <https://rajpub.com/index.php/ijct/article/view/3198>
- [13] W. Wenhong, N. Hengmao, W. Wu, and H. Niu, "An improved watershed algorithm for image segmentation," *COMPUTER MODELLING NEW TECHNOLOGIES*, vol. 18, pp. 426–431, 2014. [Online]. Available: [http://www.cmnt.lv/upload-files/ns\\_39art67\\_CMNT1812-164\\_LIG\\_Wu.pdf](http://www.cmnt.lv/upload-files/ns_39art67_CMNT1812-164_LIG_Wu.pdf)
- [14] S. Basar, M. Ali, G. Ochoa-Ruiz, M. Zareei, A. Waheed, and A. Adnan, "Unsupervised color image segmentation: A case of rgb histogram based k-means clustering initialization," *PLOS ONE*, vol. 15, p. e0240015, 10 2020. [Online]. Available: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0240015>
- [15] S. Tripathi, A. Bhardwaj, and P. E, "Approaches to clustering in customer segmentation," *International Journal of Engineering Technology*, vol. 7, p. 802, 7 2018. [Online]. Available: [https://www.researchgate.net/publication/326706602\\_Approaches\\_to\\_Clustering\\_in\\_Customer\\_Segmentation](https://www.researchgate.net/publication/326706602_Approaches_to_Clustering_in_Customer_Segmentation)
- [16] S. Wazarkar and B. N. Keshavamurthy, "A survey on image data analysis through clustering techniques for real world applications," *Journal of Visual Communication and Image Representation*, vol. 55, pp. 596–626, 8 2018. [Online]. Available: [https://www.researchgate.net/publication/326439533\\_A\\_Survey\\_on\\_Image\\_Data\\_Analysis\\_through\\_Clustering\\_Techniques\\_for\\_Real\\_World\\_Applications](https://www.researchgate.net/publication/326439533_A_Survey_on_Image_Data_Analysis_through_Clustering_Techniques_for_Real_World_Applications)
- [17] T. Feng, W. Wang, X. Wang, Y. Yang, and Q. Zheng, "Clustering based point cloud representation learning for 3d analysis," *Proceedings of the IEEE International Conference on Computer Vision*, pp. 8249–8260, 9 2023.
- [18] R. Lu, A. Zlateski, and H. S. Seung, "Large-scale image segmentation based on distributed clustering algorithms," *arXiv preprint arXiv:2106.10795*, 6 2021.