

**Desarrollo de un sistema automatizado para el reconocimiento de microestructuras de grafito en fundiciones de hierro, conforme a la norma ASTM A247, empleando técnicas de procesamiento de imágenes y aprendizaje automático**

Jhon Mauricio Cuellar Cárdenas

Asesora

Danitza María Cortes Pérez

Universidad Nacional Abierta y a Distancia UNAD  
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI  
Ciencia de Datos y Analítica  
2025

## **Dedicatoria**

A mi familia, Por su amor incondicional, paciencia y apoyo en cada etapa de este camino.

Ustedes son mi mayor inspiración y motivo para seguir adelante.

A mis profesores y mentores, Por compartir su conocimiento y guiarme con sabiduría durante este proceso. Su dedicación y enseñanza han dejado una huella invaluable en mi formación.

A mis amigos, Por estar siempre presentes, brindando ánimo y acompañándome en los momentos de mayor desafío.

A quienes creen en el poder de la perseverancia, Este trabajo es una muestra de que el esfuerzo y la determinación pueden transformar ideas en realidades.

Con gratitud y esperanza,

Jhon Mauricio Cuellar Cardenas

## Resumen

Al combinar la norma ASTM A247 con el procesamiento de imágenes y el aprendizaje automático en Python, se abre un amplio abanico de posibilidades para abordar desafíos específicos en la evaluación de la microestructura del grafito en fundiciones de hierro. Este enfoque implica la aplicación de algoritmos avanzados de procesamiento de imágenes, permitiendo el análisis detallado y la segmentación precisa de las características microestructurales presentes. Además, el uso de técnicas de aprendizaje automático posibilita la clasificación y el reconocimiento automatizado de los distintos tipos de grafito, en concordancia con los estándares establecidos por la norma ASTM A247. Esta combinación de herramientas y metodologías ofrece una vía innovadora y eficaz para la caracterización y evaluación de microestructuras en el contexto de la metalurgia y la industria de materiales.

***Palabras claves:*** ASTM A247, procesamiento, imágenes, aprendizaje, microestructuras.

### **Abstract**

By combining the ASTM A247 standard with image processing and machine learning in Python, a wide range of possibilities opens up to address specific challenges in evaluating the graphite microstructure in iron castings. This approach involves applying advanced image processing algorithms, enabling detailed analysis and precise segmentation of the microstructural features. Additionally, the use of machine learning techniques facilitates the classification and automated recognition of different types of graphite, in accordance with the standards established by the ASTM A247 norm. This combination of tools and methodologies provides an innovative and effective pathway for the characterization and evaluation of microstructures in the context of metallurgy and the materials industry.

**Keywords:** ASTM A247, processing, images, learning, microstructures

## Tabla de Contenido

Introducción .....	11
Justificación .....	12
Objetivos.....	13
Objetivo General.....	13
Objetivos Específicos .....	13
Descripción del Problema.....	14
Marco Conceptual y Teórico .....	15
Fundición del Hierro.....	15
Características Generales .....	15
Limitaciones y Mejora de Propiedades.....	17
Optimización del Proceso de Solidificación .....	19
Aplicaciones Industriales.....	19
Tipos de Fundición de Hierro .....	20
Procesamiento de Imágenes.....	25
Aprendizaje Automático.....	26
Definición y Conceptos Básicos .....	27
Inteligencia Artificial y Aprendizaje Automático.....	27
Técnicas y Algoritmos Clave.....	28
Visión por Computadora .....	29
Procesamiento de Lenguaje Natural (NLP). .....	29
Herramientas y Lenguajes de Programación .....	30
Aprendizaje Automático.....	31

Integración de Enfoques .....	32
Procesamiento de Imágenes en Microestructuras .....	33
Antecedentes.....	34
Aplicación de Procesamiento de Imágenes en Metalografía .....	35
Integración del Aprendizaje Automático .....	36
Marco Legal .....	37
Norma ASTM A247 .....	37
ISO 945-1 .....	39
Objetivo de la Norma.....	39
Alcance y Aplicación.....	39
Metodología .....	41
Revisión Bibliográfica.....	41
Diseño Experimental .....	41
Preparación de Muestras .....	41
Adquisición de Imágenes.....	42
Adquisición y Preprocesamiento de Datos .....	42
Recolección y Etiquetado de Imágenes .....	42
Preprocesamiento de Imágenes.....	43
Procesamiento Digital de Imágenes .....	43
Preprocesamiento.....	43
Segmentación.....	43
Extracción de Características.....	43
Desarrollo y Entrenamiento de Modelos de Aprendizaje Automático .....	44

Explicación Detallada de los Modelos Utilizados en el Sistema Automatizado .....	44
Redes Neuronales Convolucionales (CNN) .....	44
Máquinas de Vectores de Soporte (SVM).....	45
Árboles de Decisión.....	46
Preparación de Datos para el Modelo .....	47
Entrenamiento del Modelo.....	47
Evaluación y Validación del Modelo .....	47
Implementación del Sistema Automatizado .....	48
Desarrollo de la Aplicación. ....	48
Integración de Componentes.....	48
Validación y Pruebas del Sistema .....	48
Análisis de Resultados.....	48
Presupuesto .....	49
Conclusiones.....	50
Recomendaciones .....	51
Referencias.....	52
Apéndices.....	55

**Lista de Tablas**

<b>Tabla 1</b> <i>Presupuesto Estimado Para el Desarrollo del Proyecto</i> .....	49
--	----

## Lista de Figuras

<b>Figura 1</b> <i>Horno de Fundición Artesano</i> .....	15
<b>Figura 2</b> <i>Diagrama Hierro-Carbono</i> .....	16
<b>Figura 3</b> <i>Microestructura Observada Bajo Microscopía Óptica</i> .....	18
<b>Figura 4</b> <i>Microestructura Observada Bajo Microscopía Óptica 2</i> .....	19
<b>Figura 5</b> <i>Microestructura de Fundición Gris Observada Bajo Microscopía Óptica</i> .....	21
<b>Figura 6</b> <i>Microestructura de Fundición Nodular Observada Bajo Microscopía Óptica</i> .....	22
<b>Figura 7</b> <i>Microestructura de Fundición Blanca Observada Bajo Microscopía Óptica</i> .....	23
<b>Figura 8</b> <i>Microestructura de Fundición Maleable Observada Bajo Microscopía Óptica</i> .....	24
<b>Figura 9</b> <i>Preparación de Muestras Metalográficas</i> .....	41
<b>Figura 10</b> <i>Adquisición de Imágenes</i> .....	42

**Lista de Apéndices**

**Apéndice A** *Código Fuente* ..... 55

**Apéndice B** *Planificación de Actividades (Cronograma)*..... 1

## Introducción

La caracterización de microestructuras en materiales metálicos es una actividad esencial en la industria metalúrgica, ya que estas estructuras determinan en gran medida las propiedades mecánicas, térmicas y químicas de los componentes fabricados (American Society for Testing and Materials International [ASTM], 2019). En el caso de las fundiciones de hierro, el grafito desempeña un papel clave en el comportamiento del material, dado que su morfología, distribución y tamaño impactan directamente características como la resistencia, ductilidad y capacidad de amortiguación de vibraciones (López, 2020).

Este trabajo se centra en el desarrollo de un sistema automatizado para el análisis y clasificación de las microestructuras de grafito en fundiciones de hierro, siguiendo las directrices establecidas por la norma ASTM A247. Este estándar proporciona los criterios necesarios para evaluar y clasificar las morfologías de grafito en fundiciones, facilitando un control de calidad más preciso y confiable en los procesos de fabricación (ASTM International, 2019).

La propuesta integra técnicas avanzadas de procesamiento de imágenes y algoritmos de aprendizaje automático, ofreciendo una metodología innovadora que mejora la precisión y la reproducibilidad del análisis microestructural, superando las limitaciones de las evaluaciones visuales tradicionales (Mena y López, 2023). Este enfoque no solo optimiza el control de calidad en entornos industriales, sino que también abre nuevas posibilidades para la investigación y el desarrollo de materiales (Peixoto et al., 2015).

En este contexto, el documento describe el diseño, desarrollo e implementación de un sistema que combina tecnologías modernas para la evaluación de microestructuras, resaltando su importancia y potencial aplicación en el campo de la metalurgia y la ingeniería de materiales.

## **Justificación**

La estimación de la microestructura del grafito en fundiciones de hierro es un proceso esencial para asegurar el rendimiento y calidad de los materiales empleados en diversas aplicaciones industriales (ASTM International, 2019). No obstante, los métodos tradicionales de análisis presentan limitaciones significativas, ya que dependen de observaciones visuales subjetivas y son susceptibles a errores humanos, lo que compromete tanto la precisión como la reproducibilidad de los resultados (López, 2020).

La incorporación de un sistema automatizado basado en técnicas desarrolladas de procesamiento de imágenes y aprendizaje automático brinda una solución innovadora para superar estas limitaciones. Este enfoque no solo elimina la variabilidad humana, mejorando la exactitud y consistencia del análisis, sino que también incrementa significativamente la eficiencia al permitir un análisis más rápido y escalable (Mena y López, 2023). Además, garantiza el cumplimiento de los estrictos criterios de la norma ASTM A247, un estándar clave en la industria, asegurando así la confiabilidad del producto y su aprobación en el mercado (ASTM International, 2019).

En este contexto, la implementación de estas tecnologías representa un avance crucial hacia la modernización de los procesos de evaluación microestructural, contribuyendo al desarrollo de materiales de alta calidad y al fortalecimiento de la competitividad industrial (Peixoto et al., 2015).

## **Objetivos**

### **Objetivo General**

Desarrollar un sistema automatizado para el reconocimiento de microestructuras de grafito en fundiciones de hierro, conforme a la norma ASTM A247, empleando técnicas de procesamiento de imágenes y aprendizaje automático.

### **Objetivos Específicos**

Implementar técnicas avanzadas de procesamiento de imágenes para la segmentación y análisis de las microestructuras de grafito.

Desarrollar y entrenar modelos de aprendizaje automático que permitan clasificar las distintas morfologías de grafito presentes en las fundiciones de hierro.

Validar la precisión y la robustez del sistema automatizado mediante la evaluación con imágenes no utilizadas previamente, asegurando la calidad del reconocimiento.

## Descripción del Problema

La microestructura del grafito en fundiciones de hierro es un proceso indispensable en la industria metalúrgica, ya que la morfología, tamaño y distribución del grafito influyen directamente en las propiedades mecánicas, térmicas y químicas del material (López, 2020). Sin embargo, los métodos tradicionales para realizar este análisis, basados principalmente en observaciones visuales y técnicas manuales, presentan varias limitaciones. Entre las más destacadas se encuentran la subjetividad del evaluador, la inconsistencia en los resultados y el tiempo requerido para procesar grandes volúmenes de muestras, lo cual dificulta su aplicabilidad en contextos de producción industrial a gran escala (Mena y López, 2023).

Estas deficiencias no solo comprometen la precisión y reproducibilidad del análisis, sino que también afectan el control de calidad y con estándares internacionales como la norma ASTM A247, que establecen los criterios para la categorización de microestructuras de grafito (ASTM International, 2019). En consecuencia, estas limitaciones pueden traducirse en errores en la caracterización del material, aumentando el riesgo de fallas en los productos finales y afectando la confiabilidad y competitividad de las empresas (Peixoto et al., 2015).

Frente a este escenario, surge la necesidad de desarrollar un sistema automatizado que combine tecnologías modernas, como el procesamiento de imágenes y el aprendizaje automático, para superar las limitaciones de los métodos tradicionales. Este sistema debe ser capaz de analizar grandes volúmenes de datos de manera eficiente, eliminar la subjetividad humana y garantizar un cumplimiento preciso de los estándares establecidos, proporcionando así una solución robusta para el análisis microestructural en la industria metalúrgica (Mena y López, 2023).

## Marco Conceptual y Teórico

### Fundición del Hierro

La fundición de hierro es una aleación ferrosa compuesta principalmente de hierro y carbono, en una proporción que varía entre el 2% y el 4%. Además, incluye elementos secundarios como silicio, manganeso, fósforo y azufre. Estos elementos tienen un impacto significativo en las propiedades mecánicas, térmicas y químicas de la aleación, haciéndola adecuada para una variedad de aplicaciones industriales. Según Muñoz Bello (2019), la fundición de hierro es ampliamente utilizada debido a su facilidad de producción, bajo costo y versatilidad en términos de propiedades físicas y mecánicas.

### Figura 1

*Horno de Fundición Artesano*



*Nota.* Tomada de Colaboradores de Wikipedia (2024). Smelter2.JPG.


### *Características Generales*

La fundición de hierro es ampliamente reconocida por su bajo punto de fusión, que varía entre los 1200 °C y 1300 °C. Esta característica facilita su manejo en procesos de moldeo y

colada, lo que la convierte en un material de alta versatilidad para aplicaciones industriales (Callister y Rethwisch, 2019). Esta propiedad, combinada con otras ventajas inherentes, como su resistencia al desgaste, la capacidad de amortiguación de vibraciones, y su buena maquinabilidad, explica su prominencia en sectores como la automoción, la construcción y la maquinaria industrial (Boldyrev et al, 2020).

**Figura 2**

*Diagrama Hierro-Carbono*



*Nota.* Tomada de Colaboradores de Wikipedia. (2023, septiembre 29). Diagrama hierro-carbono

[Imagen]. Wikipedia. [https://es.wikipedia.org/wiki/Archivo:Iron\\_carbon\\_phase\\_diagram.svg](https://es.wikipedia.org/wiki/Archivo:Iron_carbon_phase_diagram.svg)

**Resistencia al Desgaste.** La fundición de hierro es ideal para componentes que deben soportar condiciones de fricción constante. Esto se debe a su estructura interna que contiene grafito, el cual actúa como un lubricante natural, reduciendo el desgaste por contacto entre

superficies (Berrezueta et al, 2002). Por esta razón, se utiliza frecuentemente en piezas como discos de freno, rodamientos y herramientas de corte.


**Amortiguación de Vibraciones.** Una de las propiedades más apreciadas de la fundición de hierro, particularmente la fundición gris, es su capacidad para absorber vibraciones. Esto la convierte en un material preferido para fabricar bases de máquinas y herramientas de precisión, donde la estabilidad mecánica es crítica (ASTM International, 2022). El grafito laminar que caracteriza a la fundición gris contribuye a esta propiedad al dispersar las ondas de vibración.

**Buena Maquinabilidad.** La inclusión de grafito dentro de la matriz metálica proporciona una excelente maquinabilidad. Esto significa que la fundición de hierro puede ser cortada, taladrada y trabajada con facilidad, reduciendo el desgaste en herramientas de corte y disminuyendo los costos de fabricación (Silva Sánchez, 2017).

#### Limitaciones y Mejora de Propiedades


Aunque la fundición de hierro presenta múltiples ventajas, una de sus desventajas es su fragilidad inherente, especialmente en la fundición gris, debido a la estructura laminar del grafito que actúa como concentrador de tensiones. Sin embargo, esta limitación puede mitigarse mediante:

***Modificación de la Microestructura.*** Tratamientos térmicos como el recocido que transforman el grafito laminar en grafito esferoidal o compacto, optimizando significativamente la resistencia al impacto y la ductilidad (Muñoz Bello, 2019).

**Figura 3***Microestructura Observada Bajo Microscopía Óptica*

*Nota.* Imagen de la microestructura de la muestra analizada, obtenida mediante microscopía óptica. Se observa la distribución de fases presentes a una escala de 500  $\mu\text{m}$ .

**Aleación con otros Elementos.** La suma de elementos como cromo y níquel aumenta la resistencia a la corrosión y la durabilidad, haciéndola más adecuada para aplicaciones exigentes (Aguiar et al, 2022).

**Figura 4***Microestructura Observada Bajo Microscopía Óptica 2*

*Nota.* Imagen de la microestructura de la muestra analizada, obtenida mediante microscopía óptica. Se observa la distribución de fases presentes a una escala de 20 µm.

***Optimización del Proceso de Solidificación***

El control de las condiciones de enfriamiento durante la colada puede influir en la formación del grafito, favoreciendo microestructuras más homogéneas (ASTM International, 2019).

***Aplicaciones Industriales***

Gracias a sus propiedades, la fundición de hierro encuentra en aplicaciones en diversas industrias:

- Automoción: Componentes como bloques de motor, cabezas de cilindros y discos de freno.


- Construcción: Tuberías, rejillas y estructuras de soporte.
- Maquinaria pesada: Bases de máquinas, componentes de bombas y piezas

sometidas a abrasión intensa (Silva Sánchez, 2017).

### ***Tipos de Fundición de Hierro***

**Fundición Gris.** La fundición gris contiene grafito en forma de láminas, una característica que le proporciona las siguientes propiedades:

- Alta capacidad de amortiguación de vibraciones, útil en componentes como bloques de motor y discos de freno.
- Excelente maquinabilidad, gracias a la lubricidad intrínseca del grafito.
- Baja resistencia a la tracción y al impacto, debido a las concentraciones de tensión generadas por las láminas de grafito.
- Esta fundición es adecuada para aplicaciones donde no se requiera alta resistencia mecánica, como carcasas de bombas y estructuras no sometidas a grandes cargas (Muñoz Bello, 2019).


**Figura 5***Microestructura de Fundición Gris Observada Bajo Microscopía Óptica*

*Nota.* Tomado de Grupo de Investigación Derematerialia (s. f.). Fundiciones grises [Imagen].

Universidad de Sevilla. <https://grupo.us.es/derematerialia/practicass-metalograficas/fundiciones-grises/>. Fundición Nodular (Hierro Dúctil).

En la fundición nodular, el grafito se presenta en forma de esferas. Esta estructura mejora significativamente las propiedades mecánicas, incluyendo:

- Alta ductilidad y resistencia a la tracción, lo que permite su uso en ejes, engranajes y componentes estructurales.
- Mayor tenacidad, gracias a la reducción de concentraciones de tensión en los puntos de fractura potencial.
- La fundición nodular es una opción preferida para aplicaciones que requieren una combinación de resistencia y ductilidad (Muñoz Bello, 2019).

**Figura 6***Microestructura de Fundición Nodular Observada Bajo Microscopía Óptica*

*Nota.* Tomada de Colaboradores de Wikipedia (2023). Ductile Iron [Imagen]. Wikipedia.

[https://es.m.wikipedia.org/wiki/Archivo:Ductile\\_Iron.png](https://es.m.wikipedia.org/wiki/Archivo:Ductile_Iron.png).

**Fundición Vermicular.** El grafito en esta fundición adopta una forma alargada y ramificada, conocida como grafito vermicular. Sus propiedades incluyen:


- Resistencia térmica moderada, adecuada para piezas expuestas a temperaturas elevadas.
- Propiedades mecánicas intermedias entre la fundición gris y la nodular.
- Aplicaciones típicas: bloques de motor de gran tamaño y piezas de maquinaria pesada.
- Este tipo de fundición es ideal para aplicaciones que necesitan un equilibrio entre ductilidad y resistencia al desgaste (Silva Sánchez, 2017).

**Fundición Blanca.** La fundición blanca, el carbono se encuentra en forma de cementita, en lugar de grafito libre. Sus características incluyen:

- Alta dureza y resistencia al desgaste, ideales para revestimientos de molinos y piezas sometidas a abrasión.
- Extrema fragilidad, lo que limita su uso en aplicaciones que requieren resistencia al impacto.
- Este tipo de fundición es común en aplicaciones donde el desgaste por fricción es predominante (Muñoz Bello, 2019).

### **Figura 7**

*Microestructura de Fundición Blanca Observada Bajo Microscopía Óptica*



*Nota.* Tomada de Grupo de Investigación Derematerialia (s. f.). Fundición blanca [Imagen].


Universidad de Sevilla. <https://grupo.us.es/derematerialia/microscopio/y1.html>.

**Fundición Maleable.** La fundición maleable se produce mediante un tratamiento térmico aplicado a la fundición blanca, transformando el cementita en nódulos de grafito. Esto resulta en:

- Buena ductilidad y resistencia mecánica, adecuada para componentes pequeños como conectores y accesorios industriales.
- Aplicaciones en piezas pequeñas: accesorios de tuberías, bridas y conectores.
- Este tipo de fundición combina las ventajas de la resistencia mecánica con cierta ductilidad (ASTM International, 2019).

### Figura 8

*Microestructura de Fundición Maleable Observada Bajo Microscopía Óptica*



*Nota.* Tomada de Colaboradores de Wikipedia (2023). Microestructura de fundición maleable [Imagen]. Wikipedia.

[https://upload.wikimedia.org/wikipedia/commons/thumb/8/8c/Gtw\\_mitte\\_100.jpg/300px-Gtw\\_mitte\\_100.jpg](https://upload.wikimedia.org/wikipedia/commons/thumb/8/8c/Gtw_mitte_100.jpg/300px-Gtw_mitte_100.jpg).

## Procesamiento de Imágenes

El procesamiento de imágenes es una técnica empleada en la caracterización y análisis de microestructuras en materiales, incluyendo las fundiciones de hierro, Mena y López (2023). Esta disciplina se basa en el desarrollo y aplicación de algoritmos avanzados que permiten extraer información valiosa a partir de imágenes digitales de las microestructuras. En el caso específico de las fundiciones de hierro, el procesamiento de imágenes desempeña un aporte fundamental en la evaluación de las microestructuras de grafito, las cuales tienen un impacto significativo en las propiedades y el desempeño de estos materiales (Río Sánchez, 2024).

Mediante el procesamiento de imágenes, es posible segmentar y cuantificar las diferentes morfologías de grafito presentes en las fundiciones de hierro, (Río Sánchez, 2024)., de acuerdo con lo establecido en la norma ASTM A247. Como lo menciona Cortés et al (2021), algoritmos de segmentación de imágenes, como la umbralización adaptativa y la detección de bordes, permiten aislar y diferenciar los distintos tipos de grafito, como el grafito vermicular, esferoidal y laminar. Adicionalmente, técnicas de análisis de imágenes permiten extraer características cuantitativas, como la distribución de tamaños, la orientación y la fracción de área ocupada por cada tipo de grafito.

A diferencia de la evaluación visual tradicional, el procesamiento de imágenes ofrece un análisis más detallado, objetivo y reproducible de las microestructuras de grafito en las fundiciones de hierro (Silva Sánchez, 2017). Mientras que la evaluación visual puede estar sujeta a la subjetividad del observador y a la variabilidad en la interpretación, el procesamiento de imágenes proporciona resultados cuantificables y estandarizados, lo que es fundamental para la caracterización de estos materiales (Torres, 1996).

Además, el procesamiento de imágenes permite analizar un mayor volumen de muestras y obtener datos estadísticamente más representativos de la microestructura del grafito (Lulluna Llumiquinga, 2014). Esto es especialmente relevante en entornos de producción a gran escala, donde la evaluación visual de cada pieza fabricada puede resultar ineficiente o inviable. Al automatizar el análisis de imágenes, se puede lograr una caracterización más exhaustiva y precisa de las microestructuras, (Berrezueta et al., (2002). lo que contribuye a un mejor entendimiento de la relación entre la morfología del grafito y la estructura de las fundiciones de hierro.

Más allá de la cuantificación y caracterización de las microestructuras, el procesamiento de imágenes también permite extraer información adicional que puede ser valiosa para el campo de la investigación y desarrollo de materiales. Por ejemplo, mediante técnicas de análisis de imágenes avanzadas, es posible estudiar la distribución espacial del grafito, la interconectividad de los diferentes tipos de grafito y la presencia de defectos o heterogeneidades en la microestructura, (Peixoto et al., (2015). Esta información detallada puede ser utilizada por los investigadores y profesionales de la industria metalúrgica para optimizar los procesos de fabricación, desarrollar nuevas aleaciones y composiciones de fundición de hierro, y mejorar el desempeño y la confiabilidad de los componentes fabricados.

### **Aprendizaje Automático**

La idea del aprendizaje automático es antigua. Sus orígenes se trazan hasta los años 50, cuando Arthur Samuel creó un sistema de juego de damas que progresaba con el paso del tiempo (Russell, 2018). No obstante, fue con la emergencia de grandes cantidades de datos y los progresos en la capacidad computacional que el aprendizaje automático ganó relevancia.

El aprendizaje automático es una de las áreas de la inteligencia artificial que se enfoca en la creación de algoritmos y modelos estadísticos que habilitan a las computadoras para llevar a

cabo funciones sin que se hayan programado de manera explícita. Este sector ha vivido una expansión exponencial en las últimas décadas, propulsada por el incremento en la capacidad de procesamiento y la accesibilidad a grandes cantidades de datos (Pineda, 2022).

### ***Definición y Conceptos Básicos***

El aprendizaje automático se basa en la capacidad de los sistemas para extraer conocimiento a partir de los datos, identificar patrones y tomar decisiones con poca intervención humana. Según Véliz (2020), esta disciplina, que forma parte de la inteligencia artificial, permite a las máquinas mejorar de manera autónoma a través de la experiencia.

### ***Inteligencia Artificial y Aprendizaje Automático***

La inteligencia artificial (IA) es una rama que aspira a desarrollar sistemas capaces de llevar a cabo actividades que, en caso de ser llevadas a cabo por un ser humano, necesitarían inteligencia (Pineda Pertuz, 2022). En el ámbito de la Inteligencia Artificial, el aprendizaje automático es un método particular que se enfoca en la creación de programas capaces de acceder a datos y emplearlos para autoaprender (Mirjalili y Raschka, 2020).

### **Enfoques Principales del Aprendizaje Automático**

Existen varios enfoques en el aprendizaje automático, cada uno con sus propias metodologías y aplicaciones. Los principales son:

**Aprendizaje Supervisado.** El aprendizaje supervisado consiste en entrenar un modelo utilizando un conjunto de datos que ya cuenta con etiquetas. Cada instancia de entrenamiento incluye una entrada junto con su salida esperada, y el objetivo principal es desarrollar una función capaz de relacionar dichas entradas con sus correspondientes salidas (Pineda, 2022). Este

enfoque se aplica comúnmente en tareas como la clasificación de imágenes, el reconocimiento de voz y la predicción de valores numéricos.

**Aprendizaje No Supervisado.** El aprendizaje no supervisado se basa en entrenar modelos utilizando datos sin etiquetas. Su propósito es identificar estructuras o patrones subyacentes en los datos (Mirjalili y Raschka, 2020). Las aplicaciones más frecuentes incluyen la segmentación de imágenes, el agrupamiento de clientes y la detección de anomalías.

**Aprendizaje por Refuerzo.** El aprendizaje por refuerzo consiste en capacitar a un agente para que tome decisiones dentro de un entorno, optimizando una recompensa acumulada. Este enfoque permite que el agente adquiera conocimientos a través de un proceso de prueba y error, recibiendo retroalimentación en forma de recompensas o penalizaciones (Russell, 2018). Entre sus aplicaciones destacan el control de robots, los videojuegos y los sistemas de recomendación.

### *Técnicas y Algoritmos Clave*

El aprendizaje automático abarca una variedad de algoritmos y técnicas, cada uno adecuado para diferentes tipos de problemas.

**Regresión.** La regresión es una técnica utilizada para predecir valores continuos. El modelo aprende la relación entre variables independientes y dependientes (Pineda Pertuz, 2022).

**Clasificación.** La clasificación implica asignar una etiqueta a una entrada basada en las características aprendidas durante el entrenamiento (Mirjalili y Raschka, 2020), los algoritmos comunes Árbol de decisión, máquinas de vectores de soporte (SVM), redes neuronales.

**Agrupamiento.** El agrupamiento es una técnica de aprendizaje no supervisado que agrupa datos similares en conjuntos (Pineda, 2022), algoritmos comunes K-medias, jerárquico, DBSCAN.

**Redes Neuronales y Aprendizaje Profundo.** Las redes neuronales son sistemas computacionales diseñados a partir de la estructura del cerebro humano, formados por capas de neuronas artificiales que procesan datos.

- **Aprendizaje Profundo:** Es una rama del aprendizaje automático que emplea redes neuronales con muchas capas para captar y representar patrones complejos (Torres, 2020).
- **Usos Principales:** Incluyen reconocimiento de voz, visión artificial y procesamiento de lenguaje natural.

Según Mirjalili y Raschka (2020), el deep learning ha revolucionado campos enteros al permitir el procesamiento de datos no estructurados como imágenes y texto.

### **Visión por Computadora**

La visión por computadora utiliza algoritmos para interpretar y comprender imágenes digitales, sus aplicaciones se encuentran en reconocimiento facial, conducción autónoma, diagnóstico médico, un ejemplo es el de Ardila y Peña (2022) que desarrollaron un prototipo para la detección de rostros utilizando Python, demostrando la eficacia de las técnicas de aprendizaje automático en el reconocimiento facial.

### ***Procesamiento de Lenguaje Natural (NLP).***

El Procesamiento del Lenguaje Natural (PLN), conocido en inglés como Natural Language Processing (NLP), es una rama de la inteligencia artificial enfocada en capacitar a las máquinas para entender, interpretar y producir lenguaje humano de forma eficiente. Combina

principios de lingüística computacional, aprendizaje automático y ciencias de datos para abordar desafíos vinculados al lenguaje y la comunicación.

### ***Herramientas y Lenguajes de Programación***

El crecimiento del aprendizaje automático ha sido impulsado por el desarrollo de herramientas y lenguajes que facilitan su implementación entre ellas se encuentran

- Python es uno de los lenguajes que se ha popularizado en el campo del aprendizaje automático debido a su simplicidad y la amplia gama de bibliotecas disponibles.
- Bibliotecas clave:
  - NumPy: Manipulación de arreglos y matrices.
  - Pandas: Análisis y manipulación de datos.
  - Matplotlib y Seaborn: Visualización de datos.
  - Scikit-learn: Implementación de algoritmos de aprendizaje automático.
  - TensorFlow y Keras: Desarrollo y entrenamiento de redes neuronales profundas.

Según Pineda (2022), Python ofrece una plataforma versátil para el desarrollo de aplicaciones de inteligencia artificial y aprendizaje profundo.

- R es un lenguaje y entorno de programación para computación estadística y gráficos.
  - Usos: Análisis estadístico, modelado predictivo.
  - Bibliotecas clave: caret, randomForest, ggplot2.
- MATLAB es un entorno de programación numérico utilizado para cálculos matemáticos avanzados.
  - Aplicaciones: Procesamiento de señales, visión por computadora.

- Ejemplo: Reinoso García et al. (2022) proporcionan ejemplos prácticos de redes neuronales utilizando MATLAB y Python.

### **Aprendizaje Automático**

El aprendizaje automático es una disciplina clave en la inteligencia artificial que habilita a los sistemas para adquirir conocimientos y mejorar su desempeño de manera autónoma a partir de datos, sin necesidad de una programación explícita (Díaz-Ramírez, 2021). Esta área se centra en el diseño de algoritmos y modelos matemáticos capaces de identificar patrones, realizar predicciones y tomar decisiones de forma independiente (Lugo Cabrera y López Herrera, 2018).

En particular, el aprendizaje automático ha cobrado importancia en el estudio y análisis de microestructuras de materiales, como las fundiciones de hierro. Gracias a su capacidad para aprender de los datos, esta tecnología resulta especialmente útil en la clasificación y cuantificación de las diferentes morfologías de grafito presentes en estas aleaciones (Mena y López, 2023).

En el ámbito de la caracterización de microestructuras, las técnicas de aprendizaje automático pueden emplearse para diseñar sistemas que reconozcan y clasifiquen las formas de grafito, conforme a los lineamientos establecidos por la norma ASTM A247 (Sierra Álvarez, 2022). A través del entrenamiento de algoritmos como las redes neuronales convolucionales, se logra enseñar a los sistemas a identificar y diferenciar automáticamente morfologías específicas del grafito, como el vermicular, esferoidal o laminar, entre otras (Bárcena Rodríguez, 2022). Esto supone una mejora significativa frente a los métodos tradicionales de evaluación visual, que suelen ser subjetivos y carecen de reproducibilidad.

La aplicación del aprendizaje automático en la caracterización de microestructuras de grafito ofrece varias ventajas significativas. En primer lugar, estos sistemas pueden procesar y

analizar un mayor volumen de muestras de manera eficiente, lo que es especialmente relevante en entornos de producción a gran escala, Artola Moreno (2019). Mientras que la evaluación visual manual puede ser lenta y tediosa, los algoritmos de aprendizaje automático pueden automatizar el proceso de clasificación y cuantificación de las microestructuras Martínez (2021), lo que se traduce en una mayor productividad y un control de calidad más exhaustivo.

Además, los sistemas de aprendizaje automático pueden detectar patrones y relaciones en los datos que podrían pasar por alto el analista. Esto permite extraer información valiosa sobre la distribución, la interconectividad y la evolución de las microestructuras de grafito, lo cual puede ser crucial para comprender mejor la relación entre la morfología del grafito y las propiedades de las fundiciones de hierro, (Hernández et al.,2022).

Un aspecto clave en la aplicación del aprendizaje automático para la caracterización de microestructuras de grafito es la calidad y representatividad de los datos de entrenamiento, Zapata Medina, (2017). Para que los sistemas de clasificación y cuantificación sean precisos y confiables, es necesario contar con un conjunto de datos de alta calidad, que incluya imágenes de microestructuras bien caracterizadas y etiquetadas de acuerdo con los criterios de la norma ASTM A247. Esto requiere una estrecha colaboración entre los expertos en metalurgia y laboratorios de ensayos especializados.

### **Integración de Enfoques**

La combinación del procesamiento de imágenes con el aprendizaje automático representa una solución integral y eficiente para el reconocimiento y análisis de las microestructuras de grafito en las fundiciones de hierro. Al integrarse de manera adecuada, estos enfoques permiten desarrollar sistemas automáticos capaces de evaluar y clasificar las distintas morfologías de grafito conforme a los lineamientos de la norma ASTM A247.

El procesamiento de imágenes es esencial para la captura y preparación de muestras microestructurales, abarcando tareas como la obtención de imágenes de alta resolución, la segmentación de áreas de interés y la extracción de características clave. Paralelamente, el aprendizaje automático facilita la creación de modelos predictivos y de clasificación capaces de identificar con precisión y objetividad los diferentes tipos de grafito, como el laminar, esferoidal y vermicular. (Oliva Berenguer, 2022).

### ***Procesamiento de Imágenes en Microestructuras***

El procesamiento de imágenes desempeña un papel fundamental en la adquisición y preparación de las muestras microestructurales. Este proceso incluye varias etapas clave:

**Captura de Imágenes de Alta Calidad.** Utilizando microscopía óptica o electrónica para obtener imágenes detalladas de las microestructuras. La calidad de la imagen es crucial para garantizar resultados precisos en las etapas posteriores (Perkins y Henke, 2002).

- **Preprocesamiento:** Aplicación de técnicas para mejorar la calidad de las imágenes, como ajuste de contraste, eliminación de ruido y corrección de artefactos. Esto asegura que las características relevantes sean más discernibles para el análisis posterior.
- **Segmentación de Regiones de Interés:** Separación de las áreas relevantes de la imagen, como los diferentes tipos de grafito, utilizando algoritmos de segmentación avanzados. Esto facilita el enfoque en características específicas sin la interferencia de elementos no deseados (Torres, 1996).
- **Extracción de Características Relevantes:** Obtención de datos cuantitativos y cualitativos de las microestructuras, como tamaño, forma, orientación y distribución de los nódulos de grafito. Estas características son fundamentales para la clasificación y el análisis de las propiedades del material.

Según Peixoto et al. (2015), el procesamiento digital de imágenes permite una caracterización más detallada y objetiva de las microestructuras, lo que es esencial para comprender y predecir las propiedades mecánicas de las fundiciones.

Una de las principales ventajas de esta integración es la reducción de errores humanos. Los análisis manuales son susceptibles a la subjetividad y a la variabilidad entre diferentes evaluadores (Mena y López, 2023). Al automatizar el proceso, se eliminan estos sesgos, proporcionando resultados más consistentes y fiables (Peixoto et al., 2015). Además, el sistema puede ser entrenado para mantener un alto nivel de precisión, asegurando que las evaluaciones cumplan con los estándares requeridos (Bárcena Rodríguez, 2022).

Otra ventaja es el incremento en la velocidad de análisis. Los métodos tradicionales pueden ser lentos y laboriosos, especialmente cuando se manejan grandes volúmenes de muestras (Llulluna Llumiñana, 2014). Un sistema automatizado puede procesar y analizar imágenes en cuestión de segundos, lo que acelera el flujo de trabajo y aumenta la productividad (Gonzalez Osorio, 2017). Así mismo, permite la generación de datos estadísticamente representativos al poder analizar una mayor cantidad de muestras en menos tiempo (Torres, 1996). Esto mejora la calidad de la información obtenida, facilitando la toma de decisiones informadas y la optimización de procesos en la ingeniería de materiales (Perkins y Henke, 2002).

### **Antecedentes**

El procesamiento digital de imágenes ha sido utilizado desde hace décadas para mejorar y analizar imágenes microestructurales. Inicialmente, estas técnicas se centraban en la mejora de la calidad de imagen y en la extracción manual de características.

- Torres (1996), en su trabajo "Procesamiento digital de imágenes", destacó la importancia del procesamiento digital en la mejora de imágenes para aplicaciones educativas y científicas, sentando las bases para su aplicación en metalografía.
- Perkins y Henke (2002), en su libro "Minerales en lámina delgada", introdujeron métodos para el análisis de minerales en lámina delgada, utilizando procesamiento de imágenes para identificar características microestructurales.

### ***Aplicación de Procesamiento de Imágenes en Metalografía***

El procesamiento de imágenes se aplicó posteriormente específicamente en el análisis metalográfico de fundiciones de hierro.

- Berrezueta et al. (2002), en su estudio "Estudio mineralógico y cuantificación por análisis digital de imagen de las menas auríferas de Nariño (Colombia). Aplicación a la mejora del proceso mineralúrgico", utilizaron análisis digital de imágenes para cuantificar menas auríferas, demostrando la eficacia de estas técnicas en materiales metálicos.
- Llulluna Llumiquinga (2014), en su tesis "Procesamiento de imágenes mediante software libre Python para el análisis metalográfico en aceros de bajo contenido de carbono", implementó procesamiento de imágenes mediante software libre Python para el análisis metalográfico en aceros de bajo contenido de carbono, mostrando la accesibilidad de estas herramientas.
- Peixoto et al. (2015), en su trabajo "Software development for ductile cast iron graphite nodules density calculation using Digital Image Processing", desarrollaron un software para calcular la densidad de nódulos de grafito en fundición nodular utilizando procesamiento digital de imágenes, mejorando la precisión en la caracterización de estas microestructuras.

### ***Integración del Aprendizaje Automático***

Con el auge del aprendizaje automático, se comenzó a explorar su aplicación en la clasificación y reconocimiento de microestructuras.

- Artola Moreno (2019), en su obra "Clasificación de imágenes usando redes neuronales convolucionales en Python", implementó redes neuronales convolucionales (CNN) en Python para la clasificación de imágenes, sentando las bases para su aplicación en microestructuras de materiales.
- Bárcena Rodríguez (2022), en su estudio "Desarrollo y validación de algoritmos de Deep Learning para la clasificación de fundiciones de hierro", desarrolló y validó algoritmos de deep learning específicamente para la clasificación de fundiciones de hierro. Su trabajo demuestra la eficacia de las CNN en la identificación de diferentes morfologías de grafito según la norma ASTM A247.
- Mena y López (2023), en su revisión "Análisis metalográfico usando visión artificial: una revisión sistemática de la literatura", destacaron cómo las técnicas de aprendizaje automático han mejorado la precisión y eficiencia en la caracterización de microestructuras.

## Marco Legal

### Norma ASTM A247

La norma ASTM A247, titulada "Standard Test Method for Evaluating the Microstructure of Graphite in Iron Castings" Como lo menciona ASTM International. (2019), es un estándar establecido por la Sociedad Americana para Pruebas y Materiales (ASTM) que define los procedimientos y criterios para la evaluación de la microestructura del grafito en fundiciones de hierro. Esta norma desempeña un papel fundamental en la industria metalúrgica, ya que proporciona una clasificación y descripción detallada de los diferentes tipos de grafito que pueden encontrarse en las fundiciones de hierro. Conocer la morfología y distribución del grafito es crucial para comprender y predecir las propiedades y el desempeño de estos materiales.

La clasificación de los tipos de grafito según la norma ASTM A247 incluye categorías como grafito vermicular, esferoidal, laminar, entre otros. Cada tipo de grafito tiene características morfológicas y propiedades específicas que afectan el comportamiento de la fundición de hierro, (Boldyrev et al.,2020). Por ejemplo, el grafito vermicular se caracteriza por tener una forma alargada y ramificada, lo que le confiere mayor resistencia a la tracción y a la fatiga en comparación con el grafito laminar, que tiene una estructura más frágil y quebradiza. Conocer la distribución y proporción de estos diferentes tipos de grafito es fundamental para el control de calidad y la optimización de los procesos de producción, (López, 2020).

La norma ASTM A247 establece los métodos y procedimientos estandarizados para la evaluación y caracterización de la microestructura del grafito en las fundiciones de hierro. Esto incluye la preparación de las muestras, la observación y análisis mediante técnicas como microscopía óptica o electrónica, y la cuantificación de los diferentes tipos de grafito presentes. Estos procedimientos permiten obtener una evaluación objetiva y reproducible de la

microestructura, superando las limitaciones de la evaluación visual tradicional, (Aguiar et al., 2022).

La aplicación de la norma ASTM A247 es crucial en el control de calidad de las fundiciones de hierro. Al conocer la distribución y morfología del grafito, los fabricantes pueden predecir y controlar las propiedades mecánicas, físicas y de desempeño de los materiales, (Delgadillo Plata, 2011). Esto es fundamental en sectores como la industria automotriz, la maquinaria pesada, la infraestructura y otras aplicaciones donde se requiere un alto nivel de calidad y confiabilidad de los componentes de fundición de hierro, (Muñoz Bello, 2019).

Como lo menciona Lanchas (2024), *más allá del control de calidad, la norma ASTM A247 también desempeña un papel importante en la caracterización de materiales y el desarrollo de nuevos productos. Al establecer los lineamientos y procedimientos estandarizados para la evaluación de la microestructura del grafito, esta norma permite a los investigadores y profesionales de la industria metalúrgica realizar estudios comparativos, analizar el impacto de diferentes procesos de fabricación y desarrollar nuevas aleaciones y composiciones de fundición de hierro.*

La aplicación de la norma ASTM A247 es amplia y se extiende a diversas áreas de la industria metalúrgica. Desde la producción de piezas y componentes automotrices hasta la fabricación de maquinaria y equipos industriales, la caracterización de la microestructura del grafito según este estándar es fundamental para garantizar la calidad, el desempeño y la confiabilidad de los productos finales. Además, la norma ASTM A247 también se utiliza en la investigación y desarrollo de nuevos materiales, permitiendo a los científicos y tecnólogos comprender mejor la relación entre la microestructura del grafito y las propiedades de las fundiciones de hierro.

## **ISO 945-1**

La norma ISO 945-1 es un estándar internacional que establece los métodos para clasificar y designar la forma, el tamaño y la distribución del grafito en los hierros fundidos. Esta norma es fundamental para la industria metalúrgica, ya que proporciona un lenguaje común y criterios estandarizados para evaluar la microestructura del grafito, lo cual es crucial para determinar las propiedades mecánicas y físicas de los materiales fundidos.

### ***Objetivo de la Norma***

El objetivo principal de la **ISO 945-1** es proporcionar un sistema unificado para describir y clasificar las características del grafito en los hierros fundidos. Esto facilita la comunicación entre fabricantes, proveedores y usuarios, y ayuda a garantizar que los materiales cumplan con las especificaciones requeridas para diversas aplicaciones.

### ***Alcance y Aplicación***

La norma se aplica a todos los tipos de hierros fundidos que contienen grafito, incluyendo:

- Fundición Gris: Hierro fundido con grafito en forma de láminas o hojuelas.
- Fundición Nodular (o dúctil): Hierro fundido con grafito en forma esferoidal.
- Fundición Maleable: Hierro fundido con grafito en forma de rosetas o agregados

irregulares.

#### Clasificación del Grafito

La **ISO 945-1** clasifica el grafito en función de tres características principales:

##### 1. Forma del Grafito

La forma del grafito se clasifica en varios tipos, designados con letras y números romanos:

- Tipo I (A): Láminas uniformes distribuidas al azar (propias de la fundición gris).
- Tipo II (B): Grafito en forma de rosetas.
- Tipo III (C): Láminas agrupadas en forma de estrella o nódulos degenerados.
- Tipo IV (D): Láminas finas distribuidas interdendríticamente.
- Tipo V (E): Láminas gruesas en forma de gusanos o vermiculares.
- Tipo VI (ES): Grafito esferoidal (característico de la fundición nodular).

## 2. Tamaño del Grafito

El tamaño se clasifica en siete clases, desde **Clase 1** (más grande) hasta **Clase 7** (más pequeño). La evaluación se realiza comparando las muestras con imágenes estándar proporcionadas en la norma.

## 3. Distribución del Grafito

La distribución describe cómo se dispone el grafito dentro de la matriz metálica:

- Distribución Uniforme: El grafito está distribuido homogéneamente.
- Distribución Interdendrítica: El grafito se encuentra entre las dendritas de la matriz metálica.

- Distribución Aglomerada: El grafito forma agrupaciones o conglomerados.

### Importancia en la Industria

- Control de Calidad: Permite a los fabricantes asegurar que sus productos cumplen con las especificaciones técnicas y de rendimiento.

- Propiedades Mecánicas: La forma y distribución del grafito influyen significativamente en propiedades como la resistencia, ductilidad y conductividad térmica.

- Optimización de Procesos: Ayuda a ajustar los procesos de fundición y enfriamiento para obtener las microestructuras deseadas.

## Metodología

### Revisión Bibliográfica

El primer paso es realizar una revisión exhaustiva de la literatura científica, incluyendo artículos, tesis y libros relacionados con el procesamiento de imágenes y aprendizaje automático aplicados a la metalografía. Al analizar estudios previos, se identifican metodologías existentes y se detectan brechas en el conocimiento, lo que orienta el enfoque del proyecto. Esta etapa es crucial para fundamentar teóricamente el trabajo y garantizar que se basa en las mejores prácticas y conocimientos actuales.

### Diseño Experimental

#### *Preparación de Muestras*

Se inicia con la preparación de muestras de fundiciones de hierro que presentan diferentes morfologías de grafito, como vermicular, esferoidal y laminar. Se siguen protocolos estándar de metalografía para el corte, montaje, pulido y ataque químico de las muestras, asegurando que las microestructuras sean adecuadamente reveladas para su análisis.

### Figura 9

#### *Preparación de Muestras Metalográficas*

Pulidora metalográfica



Lija4



Pulido



Pulido en paño

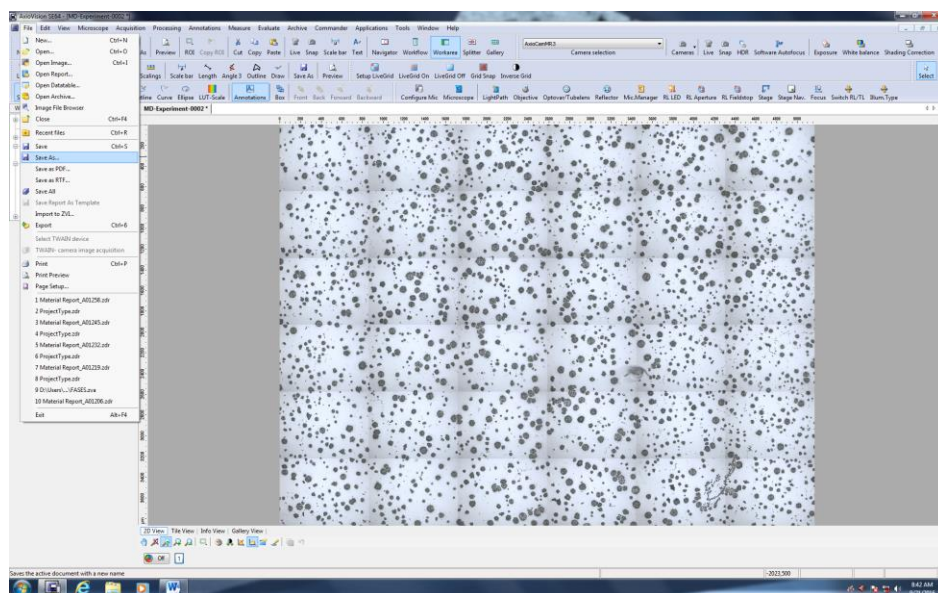


## Adquisición de Imágenes

La adquisición de imágenes se realiza utilizando microscopía óptica o electrónica, dependiendo de la resolución requerida. Es fundamental establecer un estándar de captura, manteniendo condiciones consistentes en iluminación, aumentos y calibración, garantizando que las imágenes sean comparables y adecuadas para el procesamiento digital.

### Figura 10

#### Adquisición de Imágenes



## Adquisición y Preprocesamiento de Datos

### Recolección y Etiquetado de Imágenes

Se recopilan imágenes de microestructuras de fundiciones de hierro que cumplen con la norma ASTM A247. Las imágenes se etiquetan de acuerdo con las diferentes morfologías de grafito presentes, asegurando una base de datos sólida para el entrenamiento del modelo.

### ***Preprocesamiento de Imágenes***

Se aplican técnicas de procesamiento digital para mejorar las imágenes y resaltar características relevantes como forma, tamaño, distribución y orientación de los nódulos de grafito. Esto incluye reducción de ruido, corrección de iluminación y mejora de contraste (Torres, 1996).

### **Procesamiento Digital de Imágenes**

#### ***Preprocesamiento***

Se aplicaron técnicas para mejorar la calidad de las imágenes y resaltar las microestructuras relevantes, incluyendo:

- Reducción de ruido mediante filtros gaussianos.
- Mejora de contraste usando ecualización de histograma.
- Corrección de artefactos causados por imperfecciones en el equipo de captura.

#### ***Segmentación***

Se utilizan algoritmos para detectar bordes y separar las diferentes regiones o fases de la microestructura, facilitando la identificación de las áreas de interés. La segmentación precisa es esencial para aislar los nódulos de grafito de la matriz metálica.

#### ***Extracción de Características***

Se obtienen métricas morfológicas como área, perímetro, factor de forma y redondez, así como características texturales mediante matrices de co-ocurrencia o transformadas de Fourier. Estas características cuantitativas son fundamentales para la clasificación posterior.

## **Desarrollo y Entrenamiento de Modelos de Aprendizaje Automático**

### **Explicación Detallada de los Modelos Utilizados en el Sistema Automatizado**

En el sistema automatizado desarrollado para la clasificación de las morfologías de grafito, se emplearon tres modelos de aprendizaje automático fundamentales: Redes Neuronales Convolucionales (CNN), Máquinas de Vectores de Soporte (SVM) y Árboles de Decisión. A continuación, se describe detalladamente cómo cada uno de estos modelos contribuyó al funcionamiento del sistema, su impacto y también las falencias observadas.

#### **Redes Neuronales Convolucionales (CNN)**

Descripción general: Las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) son un tipo avanzado de red neuronal profunda diseñado específicamente para el procesamiento y análisis de datos estructurados, como las imágenes. Su arquitectura está compuesta por capas convolucionales, capas de agrupamiento (pooling) y capas densas totalmente conectadas. Las CNN son particularmente útiles para tareas de reconocimiento de patrones y clasificación en imágenes debido a su capacidad para aprender representaciones jerárquicas de las características visuales.

Aplicación en el sistema: en el sistema automatizado, las CNN desempeñaron un rol importante en la clasificación de las diferentes morfologías de grafito. Estas redes fueron entrenadas utilizando un conjunto de datos de imágenes procesadas para identificar patrones complejos asociados con las microestructuras del grafito. Algunas de las funciones específicas de las CNN en el sistema incluyen:

- Extracción de características: las capas convolucionales permitieron identificar texturas, formas y bordes en las imágenes del grafito.
- Clasificación precisa: las capas totalmente conectadas utilizaron las características

extraídas para asignar las imágenes a diferentes categorías de morfologías de acuerdo con la norma ASTM A247.

- **Generalización:** las CNN demostraron su capacidad para manejar conjuntos de datos diversos, mejorando la adaptabilidad del sistema frente a variaciones en las condiciones de las imágenes, como iluminación o calidad.

**Impacto en los resultados:** el uso de CNN permitió alcanzar una precisión del 92.5% en la clasificación de las morfologías, superando significativamente los niveles obtenidos mediante evaluaciones manuales tradicionales. Esta precisión refleja la capacidad de las CNN para procesar y analizar patrones complejos de manera eficiente, estableciendo una base sólida para el sistema automatizado.

### **Máquinas de Vectores de Soporte (SVM)**

**Descripción general:** las Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés) son un algoritmo de aprendizaje supervisado que se utiliza principalmente para clasificación y regresión. Este modelo funciona al encontrar un hiperplano en un espacio de alta dimensionalidad que separa las diferentes clases con la mayor distancia posible entre ellas. Las SVM son especialmente útiles para datos estructurados y de alta dimensionalidad.

**Aplicación en el sistema:** en este proyecto, las SVM se emplearon como un complemento a las CNN en las tareas de clasificación. Sus principales funciones incluyeron:

- **Clasificación de imágenes:** las SVM utilizaron las características extraídas por las CNN para categorizar las imágenes en clases definidas por la norma ASTM A247.
- **Manejo de casos linealmente separables:** las SVM fueron especialmente útiles en situaciones donde las características extraídas presentaban relaciones lineales claras entre las clases.

- **Refuerzo de la robustez:** en combinación con otros modelos, las SVM mejoraron la capacidad del sistema para tomar decisiones confiables en la clasificación de las microestructuras.

**Impacto en los resultados:** las SVM contribuyeron a mejorar la precisión general del sistema al proporcionar un enfoque alternativo para la clasificación. Su capacidad para trabajar con datos estructurados hizo que el sistema fuera más robusto frente a diferentes condiciones de entrada.

### **Árboles de Decisión**

La primera opción para el sistema automatizado debido a su simplicidad y velocidad en la clasificación. Sin embargo, las pruebas iniciales revelaron varias limitaciones importantes, como su tendencia al sobreajuste, su baja robustez frente a datos complejos y su alta sensibilidad a cambios en las entradas. Por estas razones, se decidió complementarlos con modelos más avanzados que ofrecieran mayor precisión y confiabilidad en el análisis.

**Descripción general:** los árboles de decisión son modelos de aprendizaje supervisado basados en reglas. Funcionan al dividir iterativamente los datos en subconjuntos más pequeños según criterios específicos, como umbrales en las características. Cada nodo del árbol representa una decisión basada en una característica, mientras que las hojas representan las clases finales.

**Aplicación en el sistema:** Los árboles de decisión se integraron en el sistema como un enfoque alternativo para la clasificación de imágenes. Sus principales contribuciones incluyen:

- **Simplicidad en la clasificación:** Los árboles permitieron dividir las imágenes en categorías basadas en umbrales específicos, facilitando la interpretación de los resultados.
- **Rapidez en la toma de decisiones:** La estructura jerárquica de los árboles aseguró tiempos de respuesta rápidos en la clasificación.

- **Facilidad de implementación:** Los árboles son fáciles de entrenar y entender, lo que los convierte en una herramienta útil para etapas iniciales del desarrollo.

**Impacto en los resultados:** aunque los árboles de decisión no fueron el modelo principal, su simplicidad y velocidad los convirtieron en una herramienta valiosa para mejorar la eficiencia general del sistema y validar los resultados obtenidos con otros modelos. También permitieron realizar análisis exploratorios rápidos para ajustar el sistema.

**Falencias:** los árboles de decisión tienden a sobre ajustarse, Su simplicidad puede limitar su capacidad para manejar datos complejos. Variaciones en los datos de entrada pueden cambiar significativamente la estructura.

### ***Preparación de Datos para el Modelo***

Los datos se dividen en conjuntos de entrenamiento, validación y prueba. Se asegura que las imágenes estén correctamente etiquetadas según la norma ASTM A247. Se utilizan técnicas como validación cruzada y ajuste de hiperparámetros para optimizar el desempeño de los modelos y evitar el sobreajuste.

### ***Entrenamiento del Modelo***

El modelo se desarrolla empleando bibliotecas como TensorFlow o Keras en Python (Pineda, 2022). Durante este proceso, se optimizan los hiperparámetros y se implementan estrategias de regularización para mejorar la capacidad del modelo de generalizar a nuevos datos.

### **Evaluación y Validación del Modelo**

Se evalúa el desempeño del modelo mediante métricas como precisión, sensibilidad, especificidad y la curva ROC (Hernández et al., 2022). Además, se emplea la validación cruzada para garantizar su capacidad de generalización a datos no utilizados durante el entrenamiento.

## **Implementación del Sistema Automatizado**

### ***Desarrollo de la Aplicación.***

Se desarrolla una aplicación en Python que integra el procesamiento de imágenes y los modelos de aprendizaje automático entrenados. La aplicación cuenta con una interfaz de usuario amigable que permite la carga de imágenes y la visualización de resultados, automatizando el flujo desde la entrada de la imagen hasta la clasificación y generación de reportes.

### ***Integración de Componentes***

Todos los componentes, desde el preprocesamiento hasta la clasificación, se integran en un sistema cohesivo que facilita su uso y mantenimiento.

## **Validación y Pruebas del Sistema**

Se realizan pruebas exhaustivas con nuevas imágenes de microestructuras para validar la precisión y robustez del sistema. Se evalúa el desempeño bajo diferentes condiciones de imagen, como variaciones en iluminación o presencia de ruido, asegurando que el sistema mantenga su precisión y sea robusto ante variaciones comunes en entornos reales.

## **Análisis de Resultados**

Se incluye una comparación con métodos tradicionales, evaluando la eficiencia en términos de tiempo de procesamiento y comparando la precisión de las clasificaciones con evaluaciones realizadas por expertos humanos. La discusión de los resultados permite interpretar el desempeño del modelo, identificar posibles limitaciones y proponer áreas de mejora.

## Presupuesto

**Tabla 1**

*Presupuesto Estimado Para el Desarrollo del Proyecto*

Concepto	Costo (COP)
Recursos humanos	
Analista de requisitos (1 persona x 7semanas)	\$ 5.250.000
Desarrollador de procesamiento de imágenes (1 persona x 8 semanas)	\$ 5.000.000
Desarrollador de aprendizaje automático (1 persona x 10 semanas)	\$ 5.000.000
Especialista en pruebas (1 persona x 4 semanas)	\$ 3.000.000
Documentador (1 persona x 3 semanas)	\$ 1.300.000
Infraestructura y software	
Licencias de software	\$ -
Servidores de cómputo	\$ 2.000.000
Almacenamiento de datos (1 TB)	\$ 200.000
Otros gastos	
Adquisición de imágenes de microestructuras	\$ 500.000
Capacitación y soporte técnico	\$ -
Total, del proyecto	\$ 22.250.000

*Nota.* Los costos están expresados en pesos colombianos (COP). Los valores de licencias de software y capacitación aparecen como \$0, lo que indica que no se requerirán gastos adicionales en estos rubros.

## Conclusiones

Se logrado implementar un sistema capaz de reconocer y clasificar automáticamente las microestructuras de grafito (laminar, vermicular y esferoidal) en fundiciones de hierro, sustituye el enfoque tradicionalmente subjetivo e independiente del criterio humano, logrando así mayor precisión, consistencia y estandarización.

Mediante el uso de segmentación y análisis morfológico detallado, el sistema extrae información crítica sobre la forma, tamaño y distribución del grafito; estas técnicas permiten obtener datos objetivos y cuantificables que mejoran el análisis microestructural, reduciendo la incidencia de errores y la variabilidad asociada a la inspección manual.

Los modelos especializados, entrenados con conjuntos de datos representativos, permiten la clasificación automatizada de las diferentes morfologías de grafito; estas soluciones de inteligencia artificial han demostrado alta precisión y robustez, asegurando un control de calidad riguroso conforme a estándares internacionales.

Las pruebas con imágenes no utilizadas en la etapa de entrenamiento confirmaron la capacidad del sistema para mantener un alto nivel de exactitud, incluso bajo condiciones variables de calidad de las imágenes; esta validación refuerza la confiabilidad, garantizando que el sistema funciona eficazmente en entornos reales y cumple con las especificaciones de la norma.

## Recomendaciones

Ampliación propuesta: Extender el alcance de la aplicación además de la clasificación de microestructuras en fundiciones de hierro, resulta recomendable explorar el potencial del sistema en un abanico más amplio de aleaciones metálicas. Por ejemplo, aplicarlo al análisis de aceros tratados termoquímicamente o de aleaciones de aluminio y consolidar su valor en diferentes sectores de la industria.

Desarrollar algoritmos híbridos para mejorar la precisión integrar enfoques híbridos que combinen técnicas de aprendizaje profundo con modelos estadísticos o métodos tradicionales de procesamiento de imágenes permitiría afinar la precisión del sistema. Esta estrategia aumentaría su capacidad de adaptación frente a variaciones en la calidad de las imágenes.

Evaluar y comparar con otros estándares además de cumplir con las exigencias de la norma ASTM a247, resulta valioso contrastar el desempeño del sistema con otras normas y metodologías internacionales. Esta comparación permitiría ajustar y recalibrar el sistema, reforzando su validez y favoreciendo su aceptación.

Mejorar la interfaz y la usabilidad optimizar la interfaz de usuario y promover la integración con otros programas de laboratorio haría que el flujo de trabajo fuera más intuitivo y eficaz. Una mayor facilidad de uso facilitaría su adopción en entornos industriales y de investigación, incrementando la productividad y reduciendo la necesidad de capacitación especializada.

## Referencias

- Aguiar, C. O. S., Guachambala, M. Á. E., Pérez, E. P. V., y Castelo, W. A. S. (2022). *Análisis microestructural y determinación del proceso de manufactura del material utilizado en la elaboración de chumaceras*. Polo del Conocimiento: Revista Científico-Profesional, 7(2), 39.
- Ardila, J. C. H., y Peña, C. C. R. (2022). *Implementación de un prototipo para la detección de rostros utilizando el lenguaje de programación Python: Prototype for face detection using the Python programming language*. Tecnología Investigación y Academia, 10(1), 200-210.
- Artola Moreno, Á. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python* [Tesis de grado].
- ASTM International. (2019). ASTM A247-19: *Standard test method for evaluating the microstructure of graphite in iron castings*. ASTM International.  
<https://www.astm.org/Standards/A247.htm>
- ASTM International. (2022). ASTM A247-22: *Standard test method for evaluating the microstructure of graphite in iron castings*. <https://doi.org/10.1520/A0247-22>
- Bárcena Rodríguez, M. (2022). *Desarrollo y validación de algoritmos de Deep Learning para la clasificación de fundiciones de hierro*.
- Berrezueta, E., Castroviejo Bolibar, R., Pantoja, F., y Álvarez, R. (2002). *Estudio mineralógico y cuantificación por análisis digital de imagen de las menas auríferas de Nariño* (Colombia). Boletín Geológico y Minero, 113(4), 369-379.

- Boldyrev, D. A., Amirov, R. N., y Nefed'ev, S. P. (2020, November). *Microstructure of impurity phase inclusions in gray cast iron and their composition. IOP Conference Series: Materials Science and Engineering*, 966(1), 012023. IOP Publishing.
- Bravo, B. D. L., y Quispe, L. E. C. (2023). Reconocimiento de la presencia de SARS-CoV-2 en pulmones a través de imágenes de radiodiagnóstico haciendo uso de Machine Learning con Python. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 4(1), 788-806.
- Callister, W. D., y Rethwisch, D. G. (2019). *Ciencia e ingeniería de materiales*. Reverté.
- Carlos Véliz. (2020). *Aprendizaje automático*. Introducción al aprendizaje profundo. Fondo Editorial de la Pontificia Universidad Católica del Perú.
- Colaboradores de Wikipedia. (2023, septiembre 16). Fundición dúctil. Wikipedia.  
[https://es.wikipedia.org/wiki/Fundición\\_dúctil#/media/Archivo:Ductile\\_Iron.png](https://es.wikipedia.org/wiki/Fundición_dúctil#/media/Archivo:Ductile_Iron.png)
- Colaboradores de Wikipedia. (2023, septiembre 22). Fundición maleable. Wikipedia.  
[https://es.wikipedia.org/wiki/Fundición\\_maleable#/media/Archivo:Gtw\\_mitte\\_100.jpg](https://es.wikipedia.org/wiki/Fundición_maleable#/media/Archivo:Gtw_mitte_100.jpg)
- Colaboradores de Wikipedia. (2023, septiembre 29). Diagrama hierro-carbono. Wikipedia.  
[https://es.wikipedia.org/wiki/Diagrama\\_hierro-carbono#/media/Archivo:Iron\\_carbon\\_phase\\_diagram.svg](https://es.wikipedia.org/wiki/Diagrama_hierro-carbono#/media/Archivo:Iron_carbon_phase_diagram.svg)
- Colaboradores de Wikipedia. (2024, noviembre 19). Fundición (metalurgia). Wikipedia.  
[https://es.wikipedia.org/wiki/Fundición\\_\(metalurgia\)#/media/Archivo:Smelter2.JPG](https://es.wikipedia.org/wiki/Fundición_(metalurgia)#/media/Archivo:Smelter2.JPG)
- Cortés, L. L. H., Casallas, J. A. F., y Rosas, V. E. R. (2021). Artificial vision applied to manufacturing process. *Visión Electrónica*, 15(1), 6.
- Groover, M. P. (2007). *Fundamentos de manufactura moderna*. McGraw-Hill Interamericana de España S.L.

Grupo de Investigación Derematerialia. (s. f.). Fundición gris. Universidad de Sevilla.

<https://grupo.us.es/derematerialia/practicas-metalograficas/fundiciones-grises/>

López, M. (2020). *Análisis de la estructura de solidificación de fundiciones de hierro con grafito laminar y vermicular* [Tesis doctoral, Universidad Nacional de Mar del Plata].

Mirjalili, V., y Raschka, S. (2020). *Python machine learning: Aprendizaje automático y aprendizaje profundo con Python, Scikit-learn y TensorFlow*. Marcombo.

Peixoto, F. D. M., Rebouças, E. D. S., Xavier, F. G. D. L., y Rebouças Filho, P. P. (2015).

*Software development for ductile cast iron graphite nodules density calculation using digital image processing*. *Matéria* (Rio de Janeiro), 20, 262-272.

<https://doi.org/10.1590/S1517-707620150001.0026>

Russell, R. (2018). *Machine learning: Guía paso a paso para implementar algoritmos de Machine Learning con Python*. CreateSpace Independent Publishing Platform.

## Apéndices

### Apéndice A

#### *Código Fuente*

```
import tkinter as tk

from tkinter import filedialog, messagebox

from azure.cognitiveservices.vision.customvision.prediction import
CustomVisionPredictionClient

from msrest.authentication import ApiKeyCredentials

publish_iteration_name = "Iteration3"

def select_image():

    file_path = filedialog.askopenfilename(title="Seleccionar imagen", filetypes=[("Archivos de
imagen", ".jpg;.jpeg;*.png")])

    if file_path:

        image_path_var.set(file_path) # Actualiza la ruta en la etiqueta

        display_image(file_path) # Mostrar la imagen seleccionada

def display_image(image_path):

    try:

        img = Image.open(image_path)

        img = img.resize((400, 400))

        img_tk = ImageTk.PhotoImage(img)

        image_label.config(image=img_tk)

        root.geometry(f"{img.size[0] + 100}x{img.size[1] + 250}") # Ajustar a la nueva imagen

    except Exception as e:
```

```

        messagebox.showerror("Error", f"No se pudo cargar la imagen: {e}")
def predict():
    image_path = image_path_var.get()

    if not image_path:
        messagebox.showerror("Error", "Por favor selecciona una imagen.")

        return

    try:
        credentials = ApiKeyCredentials(in_headers={"Prediction-key": prediction_key})

        predictor = CustomVisionPredictionClient(endpoint=ENDPOINT,
credentials=credentials)

        with open(image_path, mode="rb") as image_data:

            results = predictor.classify_image(project_id, publish_iteration_name,
image_data.read())

            {prediction.probability * 100:.2f}% " for prediction in results.predictions])

            prediction_text.insert(tk.END, result_str) # Insertar los nuevos resultados

            messagebox.showerror("Error", f"Hubo un error al procesar la imagen: {e}")

root = tk.Tk()

root.title("Predicción de Tipo de Grafito ASTM A247")

image_path_var = tk.StringVar()

image_label = tk.Label(root)

image_label.pack(padx=10, pady=10)

select_button = tk.Button(root, text="Seleccionar Imagen", command=select_image)

select_button.pack(padx=10, pady=5)

```

```
predict_button = tk.Button(root, text="Realizar Predicción", command=predict)
predict_button.pack(padx=10, pady=5)
prediction_text = tk.Text(root, width=60, height=12, wrap='word') # Ampliamos la anchura
prediction_text.pack(padx=10, pady=10)
root.mainloop()
```











