

**Desarrollo de un modelo para la caracterización y clasificación de lesiones en imágenes de resonancia magnética de mama basado en aprendizaje computacional.**

**ALEJANDRO GARCIA HERRERA**

**INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO  
FACULTAD DE INGENIERÍA  
INGENIERÍA DE SOFTWARE  
MEDELLÍN  
2025**

**Desarrollo de un modelo para la caracterización y clasificación de lesiones en imágenes de resonancia magnética de mama basado en aprendizaje computacional.**

**ALEJANDRO GARCIA HERRERA**

**Trabajo de grado para optar al título de Ingeniero de Software**

**Asesor**

**RUBEN DARIO FONNEGRA TARAZONA**

**INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO**

**FACULTAD DE INGENIERÍA**

**INGENIERÍA DE SOFTWARE**

**MEDELLÍN**

**2025**

# Contenido

Pág.

## Contents

Contenido.....	3
Pág.....	3
Lista de figuras.....	5
Pág.....	5
Pág.....	6
Resumen.....	6
Abstract.....	7
1. Planteamiento del problema.....	10
1.2 Formulación.....	10
2. Justificación.....	12
3. Objetivos.....	13
3.2 Objetivos específicos.....	13
4. Marco teórico.....	14
5. ....	14
6. Metodología.....	19
5.2 Método.....	19
5.3 Población y muestra.....	21
5.4 .....	21
5.5 Instrumentos de recolección de información}.....	21
En este caso, los instrumentos de recolección de datos que se utilizaran para este trabajo de investigación son artículos académicos sobre la implementación del modelo MoCo, artículos sobre el Deep learning y publicaciones médicas acerca del diagnóstico de resonancia magnética.....	21
7. Resultado.....	22
El presente proyecto se enfoco en el desarrollo de un modelo para la clasificación de lesiones de cáncer de mama por medio de imágenes de resonancia magnética (MRI) con el objetivo de contribuir a una valoración más rápida y objetiva de cada uno de los diagnósticos. Los resultados obtenidos permiten concluir que la creación de modelos de este tipo puede mejorar mucho esta clase de procesos evaluados por especialistas al igual que pueden contribuir como herramienta complementaria para estos.....	22
6.1 Separación de embeddings aprendidos con el modelo MoCo.....	22
Para esto se generaron embeddings de 2048 dimensiones utilizando el modelo MoCo entrenado sobre el conjunto de validación del dataset Bread DM, donde se busca visualizar de manera las características aprendidas por el modelo al igual que el comportamiento de ambas clases (benigna y maligna) dentro de un espacio de agrupamiento local. Estos embeddings fueron reducidos por UMAP lo que pudo permitir su representación en un plano bidimensional.....	22
En el plano podemos observar un dominio evidente de los puntos rojos (lesiones malignas), los cuales tienden a agruparse de manera compacta a diferencia de los puntos azules (lesiones benignas) que a pesar de que casi no tienden a mostrarse mucho en el plano, tienden a tener grupos separados y dispersos. Esto	

dando a entender que las lesiones malignas presentan patrones visuales más consistentes y fácilmente identificables por el modelo, teniendo un mejor desempeño en la identificación de lesiones malignas y mayor confusión en las benignas.....	22
6.2 Evaluación del modelo con KNN.....	23
KNN es un método de clasificación supervisado basado en la similitud entre sus datos, para este caso, este modelo se utilizó ya que a base de los embeddings obtenidos en el entrenamiento se puede realizar una clasificación de las imágenes de las lesiones malignas y benignas. Se probaron diferentes valores de K donde se buscaba identificar el número óptimo de vecinos para la clasificación de las lesiones benignas y malignas donde muestran que $k=1$ y $k=3$ obtuvieron el mejor desempeño, alcanzando un “Accuracy” del 95.98%, acompañado de otras métricas como precisión, Recall score y F1 Score. Esto mostrando que el modelo tuvo una alta efectividad en cuanto a la detección de lesiones malignas, mientras mantiene una tasa baja de falsos positivos. A medida que el valor de K aumenta, el desempeño va disminuyendo progresivamente, esto debido a la dispersión de la clase benigna en el espacio de embeddings. Este comportamiento muestra que las representaciones aprendidas en base al modelo MoCo genera agrupamientos suficiente definidos como para que un clasificador como KNN pueda lograr resultados sobresalientes.....	23
8. Conclusiones.....	27
10. Referencias bibliográficas.....	29

## Lista de figuras

	Pág.
<b>Ilustración 1.</b> Proceso de un modelo de aprendizaje automático	19
<b>Ilustración 2</b> Mapeo de embeddings del modelo MoCo con UMAP	25
<b>Ilustración 3</b> Porcentajes de evaluación del modelo MoCo con KNN	26
<b>Ilustración 4.</b> Gráfico de curva ROC-AUC	27
<b>Ilustración 5.</b> Predicción del modelo MoCo en MRI	28
<b>Ilustración 6.</b> Matriz de confusión modelo MoCo	29

## Resumen

### **Desarrollo de un modelo para la caracterización y clasificación de lesiones en imágenes de resonancia magnética de mama basado en aprendizaje computacional.**

**ALEJANDRO GARCIA HERRERA**

El cáncer de mama constituye una de las principales causas de mortalidad en las mujeres a nivel mundial y la detección de un diagnóstico temprano depende en gran medida de la interpretación experta de imágenes de resonancia magnética. Este diagnóstico es determinado por medio de especialistas los cuales son quienes analizan imágenes de resonancia magnética para determinar si este tipo de lesiones son benignas o malignas, pero este proceso puede presentar una variabilidad debido a que ciertos tipos de lesiones tienen una similitud visual lo cual puede retrasar o dificultar una detección temprana y puede retrasar en parte el pronóstico de un paciente

Para ello, el presente proyecto propone la implementación de un modelo de aprendizaje autosupervisado, utilizando el modelo MoCo (Momentum Contrast) para extraer representaciones significativas de MRI transformándose a una imagen contrastada y extrayendo embeddings donde serán evaluadas por medio de un clasificador KNN (K Nearest Neighbors) comparando las diferentes representaciones presentes en el conjunto de datos y evaluando el modelo por medio de métricas de desempeño. Adicionalmente implementando técnicas como UMAP para visualizar la separación entre las lesiones benignas y malignas al igual que mostrar una matriz de confusión y una curva ROC-AUC como métricas clínicas relevantes

Los resultados indican que el modelo es capaz de generar representaciones que puedan facilitar la diferenciación entre este tipo de lesiones ofreciendo un apoyo potencial frente al diagnóstico médico, donde podría servir como herramienta complementaria para los especialistas, contribuyendo a una valoración más rápida y objetiva en este de contexto

**Palabras claves:** Cáncer de mama, aprendizaje autosupervisado, MoCo (Momentum Contrast), Clasificación, Diagnóstico

## **Abstract**

### **Development of a model for the characterization and classification of breast magnetic resonance imaging lesions based on computational learning**

ALEJANDRO GARCIA HERRERA

Breast cancer remains one of the leading causes of mortality among women worldwide, making early detection essential to improve survival rates and enable timely treatment. Breast magnetic resonance imaging (MRI) is one of the most sensitive imaging techniques for identifying lesions, as it provides high contrast and structural detail. However, its interpretation largely depends on the expertise of radiologists, and due to the visual similarity among certain lesions, the diagnostic process may involve variability and delay, potentially affecting patient prognosis.

This project proposes the implementation of a self-supervised learning model using MoCo (Momentum Contrast) to extract meaningful representations from MRI scans, transforming them into contrastive images and generating embeddings that are later evaluated through a KNN (K-Nearest Neighbors) classifier. The model is assessed using performance metrics, and additionally, techniques such as UMAP are applied to visualize the separation between benign and malignant lesions, along with the generation of a confusion matrix and a ROC-AUC curve as relevant clinical indicators.

The results indicate that the model is capable of generating representations that facilitate the differentiation between these types of lesions, offering potential support for medical diagnosis, where it could serve as a complementary tool for specialists, contributing to faster and more objective evaluation within this context.

*Keywords:* Breast cancer, self-supervised learning, MoCo, classification, diagnosis

## Glosario

**Aprendizaje Autosupervisado:** modelo de aprendizaje automático que no necesita de etiquetas externas para realizar su aprendizaje

**Accuracy:** métrica de predicción sobre el total de una muestra o conjunto de datos evaluado

**Backbone:** componente de un modelo para extraer un conjunto de características mediante datos de entrada como imágenes

**Contrastive Loss:** función de pérdida de aprendizaje que permite calcular la distancia euclidiana entre pares de vectores

**Dataset:** conjunto de datos estructurado utilizado para entrenar y validar modelos de aprendizaje automático

**Embeddings:** representaciones vectoriales de los datos de entrada de un modelo de aprendizaje

**MoCo (Momentum Contrast):** modelado de aprendizaje contrastivo que utiliza una red de momento que permite por medio de las representaciones contrastivas generadas comparar pares positivos y negativos

**Matriz de confusión:** herramienta para visualizar el rendimiento de un modelo de clasificación

## **Introducción**

El cáncer de mama es un tipo de cáncer no transmisible hereditario, el cual se origina en el tejido mamario y que puede ser mortal si no se realiza un diagnóstico temprano de este. Este cáncer es una enfermedad causada por la progresiva acumulación de aberraciones genéticas haciendo que este eleve su riesgo en un 50% de los casos donde en su mayoría no se identifica y que más adelante puede jugar un papel muy crucial dependiendo del tiempo de su detección. Dado a esto al momento de realizar una toma de decisiones frente a este tipo de diagnóstico es algo vital a pesar de que hoy en día este proceso está ligado a la percepción de los radiólogos expertos, lo cual puede introducir variabilidades y sesgos por percepción dependiendo de la carga laboral en los radiólogos.

Por otra parte, el avance de equipos computacionales y máquinas para el diagnóstico a etapa temprana de este cáncer juega un papel muy importante en el avance del desarrollo de la salud, ya que en ciertas aplicaciones médicas no se depende como tal de la percepción de un experto llevando así a la implementación de nuevas tecnologías como ha sido el reconocimiento de patrones y las inteligencias artificiales dando así la importancia de estos tópicos y su aplicación en algunas áreas de la salud y de la vida.

## 1. Planteamiento del problema

### 1.1 Descripción

La resonancia magnética es una técnica que se utiliza especialmente para la detección de enfermedades y diagnósticos por medio de un campo magnético y ondas de radio generadas por una computadora utilizada para generar imágenes detalladas de los tejidos corporales. La mayoría de los dispositivos de resonancia magnética son grandes imanes en forma de cilindro realizando así un monitoreo del paciente y haciendo un seguimiento a cómo van los tratamientos de alguna enfermedad diagnosticada. El pensamiento computacional con el paso del tiempo ha desarrollado nuevos métodos para la automatización de ciertos procesos tecnológicos en el mundo, tales como reconocimiento de patrones, inteligencia artificial, automatización para problemas de clasificación entre otras cosas. A diario, vemos que se publican nuevos avances en el desarrollo de nuevas tecnologías referentes al campo de la medicina, donde se realizan investigaciones para tratar con ciertas enfermedades e ir determinando cual es el tipo o que riesgo tienen estas, es decir, se tienen nuevas ideas para la implementación de tecnologías en ciertos campos de la medicina como lo fueron los marcapasos o también, los mamógrafos para la detección de quistes de mama en sus etapas iniciales, tomar información acerca de los radiólogos y su función. Como tal parte de la automatización de procesos va de la mano de este tipo de elementos, ya que se busca automatizar un proceso por medio de un sistema sin tener que recurrir a la ayuda de un radiólogo para determinar este tipo de enfermedades.

### 1.2 Formulación

**¿Qué tipo de modelo basado en representación de datos diferenciaría y clasificaría entre lesiones de resonancia magnética de mama benignas y malignas?**

Existen modelos computacionales con capacidad de diferenciar y clasificar lesiones mamarias en imágenes de resonancia magnética (MRI), entre ellos destacan los modelos basados en Deep Learning como las redes neuronales convolucionales (CNN) las cuales son ampliamente utilizadas por su eficiencia en el procesamiento de imágenes médicas. Sin embargo, también

existen otros modelos con enfoques más avanzados como los modelos híbridos que utilizan Visión Transformers, los cuales dividen las imágenes en pequeños parches o tokens visuales, permitiendo que la red neuronal aprenda de proyecciones globales y dependencias locales de manera más eficaz. Además, estos tokens visuales son susceptibles de clasificación ya que contienen información de importancia y de ubicación espacial, lo cual permite realizar interpretaciones en función de la representación obtenida en las imágenes. De esta forma, los vision transformers han mostrado resultados competitivos en tareas de análisis de imágenes, y particularmente en interpretación y clasificación de tareas a partir de ellas.

La elección del modelo depende de ciertos factores como lo son la calidad y cantidad del dataset, el tipo de información que se va a procesar y el nivel de precisión requerido. Todos estos modelos permiten automatizar el proceso de diagnóstico reduciendo la dependencia del análisis del ser humano y mejorando la detección temprana y clasificación precisa de las lesiones mamarias

## 2. Justificación

El cáncer de mama a día de hoy sigue siendo una de las principales causas de mortalidad en mujeres a nivel mundial, por lo que su detección temprana resulta fundamental para mejorar las tasas de supervivencia y así proponer un tratamiento temprano que pueda ayudar a la paciente afectada. La resonancia magnética de mama (MRI) es una de las técnicas de imagen más sensibles para la identificación de lesiones, ya que permite visualizar estructuras con un contraste y detalle alto. Sin embargo, la interpretación de estas imágenes depende en gran medida de la experiencia de un radiólogo, dado que a ojo humano no se podría producir un diagnóstico conveniente para el paciente.

En este contexto, se busca un enfoque basado en aprendizaje computacional (Machine learning) y Deep learning donde estos representan una alternativa robusta para apoyar la toma de decisiones clínicas. Modelos de este tipo permiten clasificar lesiones, reduciendo la dependencia del criterio de un radiólogo como lo es en este tipo de casos.

El uso de base de datos públicas como lo es BreastDM, proporciona un entorno amplio para proponer, evaluar y entrenar algoritmos de clasificación ya que las imágenes contienen anotaciones de lesiones y diagnósticos confirmados (Benigno/Maligno, Lesión/No Lesión). Este tipo de recursos permite aplicar enfoques más avanzados como el aprendizaje auto supervisado. En este proyecto, la implementación de MoCo (Momentum Contrast) resulta especialmente relevante, ya que este método permite aprender representaciones discriminatorias de las imágenes sin depender exclusivamente de una etiqueta. El modelo se basa en agarrar ambas “etiquetas” en este caso que son las lesiones benignas y malignas, por medio transformaciones de aumento de datos de estas imágenes se busca entrenar el modelo en modo contrastivo para capturar patrones estructurales y contextuales de las imágenes de resonancia magnética (MRI), donde posteriormente estas representaciones serán utilizadas en tareas de clasificación supervisada con un menor volumen de datos anotados.

De esta manera, la combinación de este dataset “BreastDM” con un enfoque auto supervisado como lo es el modelo MoCo (Momentum Contrast) permitiendo aprovechar toda la información visual disponible y reducir la dependencia de la subjetividad humana en el diagnóstico

### **3. Objetivos**

#### **3.1 Objetivo general**

Desarrollar un modelo basado en aprendizaje computacional para la caracterización y clasificación de lesiones anotadas (lesión/no lesión) en imágenes de resonancia magnética de mama.

#### **3.2 Objetivos específicos**

- Utilizar técnicas de preprocesamiento y aumentación para estandarizar las entradas del modelo y crear vistas contrastivas de las lesiones de resonancia magnética benignas y malignas para que faciliten el entrenamiento del modelo autosupervisado
- Desarrollar un modelo de clasificación que, sin utilizar etiquetas directamente en la fase de entrenamiento para determinar su clasificación, extraiga rasgos relevantes de las imágenes obtenidas por resonancia magnética.
- Examinar el desempeño de los algoritmos desarrollados para la clasificación de estas muestras

## **4. Marco teórico**

### **4.1 Diagnóstico de las lesiones mamarias**

“La mamografía es el único método diagnóstico aceptado como técnica de despistaje para el cáncer de mama permitiendo su detección precoz y el único que ha demostrado una reducción de las tasas de mortalidad por cáncer de mama”.

“El sistema Breast Imaging Reporting and Data System (BI-RADS) es un método para clasificar los hallazgos mamográficos que actualmente se considera el idioma universal en el diagnóstico de la patología mamaria. Permite estandarizar la terminología y la sistemática del informe mamográfico y categorizar las lesiones estableciendo el grado de sospecha y asignar la actitud a tomar en cada caso.”

### **4.2 Métodos alternativos de diagnóstico en cáncer de mama**

#### **4.2.1 Resonancia Magnética de Mama (MRI)**

“El cáncer de mama es una de las causas más frecuentes por las cuales las mujeres tienden a tener un gran porcentaje de mortalidad respecto a esta enfermedad. Con la implementación de sistemas computacionales se ha convertido en un reto en el cual se puede mejorar el diagnóstico médico de estos tumores mamográficos que encontramos en las mamografías. Se propone un sistema de clasificación del diagnóstico asistido por ordenador basado en técnicas de Deep Learning, específicamente en redes neuronales de convolución (CNN). El sistema se divide en dos partes: en la primera, se realiza un preprocesamiento sobre las mamografías extraídas de una base de datos pública; posteriormente, las CNNs extraen características de las imágenes preprocesadas para finalmente clasificarlas en función de los dos tipos de tumores existentes: benignos y malignos. Los resultados de este estudio muestran que el sistema tiene una precisión del 80% en clasificación de tumores.”

#### **4.2.2 Ecografía y limitaciones**

“Debido a su elevada sensibilidad se pueden llegar a resolver contratiempos y limitaciones manifestadas en otras modalidades de diagnóstico por imagen como serían la mamografía o la ecografía. La extracción y evaluación de las características de textura y de forma en las distintas regiones de interés de la mama conforman un aspecto muy determinante para la exhaustiva

comprensión de las imágenes médicas y, en consecuencia, la realización de un adecuado diagnóstico de la paciente en función de aquellas características más significativas.”

#### **4.2.3 Proceso de análisis de imágenes de mama dentro del pensamiento computacional**

“El diagnóstico correcto de las imágenes de DCE-RM de tumores de mama está determinado en gran medida por la calidad de la visualización, la experiencia operativa y el tiempo requerido para el análisis de los datos. Debido al análisis manual de cortes de resonancia magnética (RM), que requiere mucho tiempo y es propenso a errores, se han explotado enormes sistemas especializados para ayudar a los radiólogos a detectar o diagnosticar lesiones mamarias. La extracción de características es un paso clave en estos sistemas especializados para la segmentación y clasificación de tumores de mama. Los primeros métodos convencionales de extracción de características artesanales contienen características estadísticas y características de textura para detectar o diagnosticar lesiones mamarias”

#### **4.3 Importancia del diagnóstico temprano y limitaciones actuales**

Como tal no hay en concreto una profundización sobre algoritmos sobre la clasificación de resonancias magnéticas de lesiones de mama, como se aprecia es la descripción de los procedimientos y la importancia o impacto para los diagnósticos tempranos en cada uno de los pacientes, ya que al tener un diagnóstico tardío sobre esta enfermedad no se podría evitar las consecuencias que traen esta enfermedad. El impacto temprano y su clasificación, en los artículos indagados se muestran las técnicas las cuales van ligado de la mano a la segmentación de características y las regiones de interés las cuales son características que se van a utilizar para determinar la clasificación de las lesiones mamarias.

#### **4.4 Conjuntos de datos disponible**

Sin embargo, existen muy pocos conjuntos de datos públicos de DCE-MRI de mama para la segmentación y clasificación de estos tumores de mama. “Mader et al. [20] proporcionaron un conjunto de datos de mamografía digital mamaria llamado mini-MIAS (Sociedad de Análisis de Imágenes Mamográficas) con 322 muestras de imágenes (208 normales y 114 anormales). Moreira et al. [21] construyeron un conjunto de datos mamográficos digitales (FFDM) de campo completo que consta de 115 casos (410 imágenes). David et al. [22] presentaron una colección

llamada Breast-MRI-NACT-Pilot que incluye estudios longitudinales de resonancia magnética dinámica con contraste mejorado de 64 pacientes que recibieron tratamiento de quimioterapia neoadyuvante (NACT) para el cáncer de mama invasivo”

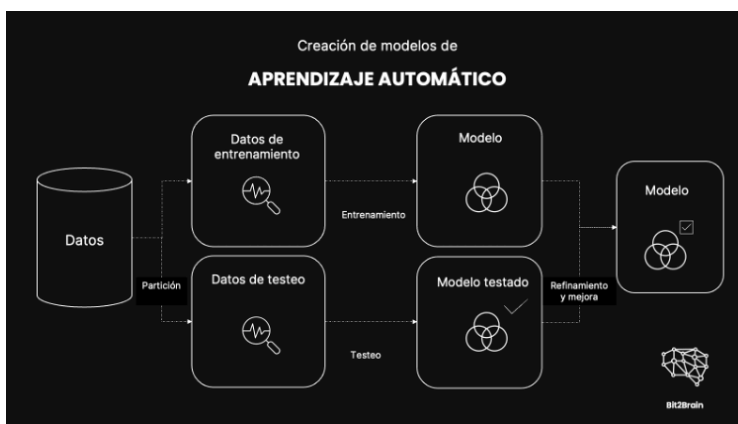
#### 4.5 Métodos propuestos para la clasificación de lesiones mamarias

Teniendo en cuenta esta información, ciertas bases de datos han sido trabajadas este tipo de lesiones, sin embargo, en la actualidad sigue siendo una necesidad urgente un conjunto de datos públicos de DCE-MRI de mama con imágenes de un tamaño grande y con una alta resolución de calidad para la segmentación y clasificación de tumores de mamá.

En base a esto, se proponen métodos para la realización de la clasificación de estas lesiones de mama donde se piensan utilizar métodos convencionales hechos a mano y métodos de última generación basados en aprendizaje profundo (Deep Learning) para la segmentación y clasificación de tumores de mama.

#### 4.6 Modelo de Aprendizaje Automático

Existen técnicas estadísticas o también modelos basados en redes neuronales. Este tipo de aprendizaje autónomo requiere la definición de un modelo con unos hiper-parámetros, que básicamente definen como el sistema va a aprender. Por otro lado, este tipo de modelos necesitan un gran conjunto de datos de entrada (ejemplos o muestras, en este caso serían imágenes de MRI) a los que generalmente se les aplica una limpieza y un pre proceso previo para que se adapten a un cierto formato de entrada y también para facilitar el trabajo de aprendizaje del modelo



*Ilustración 1. Proceso de un modelo de aprendizaje automático*

#### **4.6 Deep Learning**

Este tipo de aprendizaje de máquinas es una técnica de aprendizaje autónoma basada en redes neuronales donde su principal característica es que los datos de entrada suelen requerir menos reproceso ya que como tal es el modelo que se encarga de sí mismo de analizar los datos e interpretar la información o características relevantes. “Su detección, segmentación, seguimiento y clasificación rápida y robusta de objetos fisiopatológicos estructuras anatómicas, puede ayudar a los médicos durante el flujo de trabajo clínico de rutina.” (Tsuneki, 2022)

Este tipo de aprendizaje puede ser más robusto con varias características para identificar clases teniendo en cuenta que su conjunto de entrenamiento debe de contener una gran cantidad de datos para que su análisis pueda ser diverso. Siendo el caso que, para este tipo de diagnósticos médicos, estos modelos de aprendizaje presentan un limitante en ciertas ocasiones y es que las instituciones médicas no disponen de suficientes imágenes médicas para los conjuntos de entrenamiento. El mejoramiento de aplicaciones basadas en este tipo de aprendizaje podría llegar a tener un gran impacto a la hora de garantizar diagnósticos que se deben de hacer por parte de los especialistas ya que es el método tradicional por el cual se determinan los diagnósticos y tratamientos para cada una de las diferentes lesiones en el tema de este tipo de imágenes médicas.

#### **4.7 Método Supervisado (Supervised Method)**

El método supervisado es un tipo de aprendizaje automático el cual consta de etiquetas de entradas las cuales son requisito para entrenar un modelo en concreto y realizar predicciones de sus resultados. Este tipo de aprendizaje consta de ciertas etapas previas para llevar a cabo su realización, esas etapas constan en preprocesamiento del conjunto de datos, construcción del modelo predictivo y la validación del modelo utilizando métricas de comportamiento.

Para este caso se utilizan datos (imágenes) de muestras mamarias clasificadas por etiquetas benignas o malignas donde por medio del modelo MoCo se busca realizar una clasificación por medio de su contraste. MoCo, como cualquier método diferenciado es un método auto supervisado, es decir que a medida que el modelo se entrena esta ira aprendiendo características de cada una de las diferentes etiquetas que tienen las imágenes para ir diferenciándolas en la

evaluación del modelo. Para este tipo de casos donde se requieren modelos que necesiten diferenciar entre una o más características, se utilizan métodos de aprendizaje supervisado y no supervisado donde:

“En el aprendizaje supervisado, el sistema se entrena con datos específicos y luego intenta predecir los resultados de nuevos datos de prueba. En el aprendizaje no supervisado, el sistema no cuenta con datos de entrenamiento previos, solo con datos de entrada, y por lo tanto se adapta a estos datos para generar predicciones” (Roncales, 2024)

#### **4.8 Momentum Contrast Model (MoCo)**

Este modelo del aprendizaje es una técnica de aprendizaje autónomo que enseña al modelo puntos o características de datos son similares o diferentes mediante el uso de representaciones que permiten que, por medio de las características tomadas, los elementos similares sean iguales y los elementos diferentes sean diferentes (He et. al, 2020). “Los métodos auto supervisados permiten la construcción de modelos que aprenden representaciones de imágenes en grandes conjuntos de imágenes sin etiquetar; estos modelos pueden luego ajustarse en conjuntos de datos más pequeños para diversas tareas. Dado que el cáncer de mama es una de las principales causas de muerte entre las mujeres en todo el mundo, la clasificación precisa de las lesiones es crucial para detectar casos malignos” (Mika Ami, 2021)

Una vez los datos son procesados por medio de este modelo sin la necesidad de tener etiquetas las cuales permiten clasificar los datos, este funciona de acuerdo a un codificador de momento que permite generar tokens visuales mucho más estables, lo que permite abarcar un diccionario de muestras negativas dinámicas mejorando la eficiencia de aprendizaje sin requerir tamaños de lote masivos.

“El aprendizaje autosupervisado generalmente implica dos pasos: (1) aprovechar datos extensos no etiquetados para construir tareas proxy para obtener un modelo previamente entrenado con características generales de imagen, y (2) ajustar el modelo previamente entrenado con datos anotados disponibles para tareas posteriores.” (Xianqi Meng, 2025)

## 5. Metodología

### 5.1 Tipo de proyecto

El proyecto es de tipo exploratorio y aplicado. Exploratorio ya que lo que se busca es analizar las representaciones de resonancia magnética de mama y como pueden ser representadas por medio de un modelo de aprendizaje autosupervisado como lo es el modelo MoCo (Momentum Contrast) teniendo en cuenta las características y los patrones visuales que permitan diferenciar las lesiones benignas y malignas sin necesidad de etiquetas durante la fase de entrenamiento

Es aplicado porque se pone en marcha un modelo que permite clasificar las lesiones de resonancia magnética (MRI) según su funcionamiento, utilizando las representaciones aprendidas a través del modelo MoCo. El objetivo es examinar su utilidad desde el punto de vista del diagnóstico mediante técnicas de Deep learning y la implementación de clasificadores como KNN.

### 5.2 Método

**Utilizar técnicas de preprocesamiento y aumentación para estandarizar las entradas del modelo y crear vistas contrastivas de las lesiones de resonancia magnética benignas y malignas para que faciliten el entrenamiento del modelo autosupervisado**

Para cumplir con este objetivo, se busca hacer un análisis en el cual permita hacer un preprocesamiento de las imágenes de resonancia magnética, ya que su base de datos abarca una gran variedad de datos como lo son las máscaras de segmentación y sus etiquetas pero solo se tomara en cuenta para esta sección la parte de los datos de entrenamiento donde se busca realizar una normalización de los datos y extraer los embeddings de cada una de las representaciones para la preparación del modelo de aprendizaje autosupervisado

**Desarrollar un modelo de clasificación que, sin utilizar etiquetas directamente en la fase de entrenamiento para determinar su clasificación, extraiga rasgos relevantes de las imágenes obtenidas por resonancia magnética.**

Para llevar a cabo el desarrollo de este objetivo, se implementará un modelo de aprendizaje autosupervisado llamado Momentum Contrast (MoCo) el cual, por medio de los embeddings de las representaciones contrastadas y un codificador permitan realizar la extracción de datos de las diferentes imágenes que hay en el conjunto de datos previamente cargado, conllevando así la extracción de los datos para ambas lesiones tanto benignas como malignas

**Examinar el desempeño de los algoritmos desarrollados para la clasificación de estas muestras**

Lo que se realizará para efectuar este objetivo, será evaluar el modelo contrastivo por medio de métricas de desempeño como KNN (K-nearest neighbor) y Umap. KNN se encarga de comparar cada embedding por medio de sus vecinos asignando así una etiqueta en base a su predicción. A partir de estas predicciones se calculan las métricas de desempeño como Accuracy, Precision, Recall, F1-Score donde también se construye una matriz de confusión, donde permite evaluar las representaciones generadas por el modelo autosupervisado

Adicionalmente, se utiliza UMAP (Uniform Manifold Approximation & Projection) como técnica de reducción de dimensionalidad de los embeddings donde permite visualizar la estructura latente de los datos, verificando que los clusters de ambas clases benignas y malignas queden separados por grupos mostrando así una separación visual en base a lo que el modelo haya aprendido

Estas evaluaciones permiten determinar si las representaciones aprendidas por el modelo poseen calidad suficiente para ser empleadas en una tarea de clasificación posterior, validando la efectividad del enfoque autosupervisado en el enfoque de lesiones de MRI

### **5.3 Población y muestra**

Aunque no se trabaja con personas directamente, la población para este estudio se considera por el conjunto de datos disponible ya que estas representan casos clínicos reales de cada persona anónima. La muestra para este trabajo de investigación es el subconjunto de imágenes utilizado en cada fase del proyecto.

### **5.4 Instrumentos de recolección de información}**

#### **5.4.1 Fuentes primarias.**

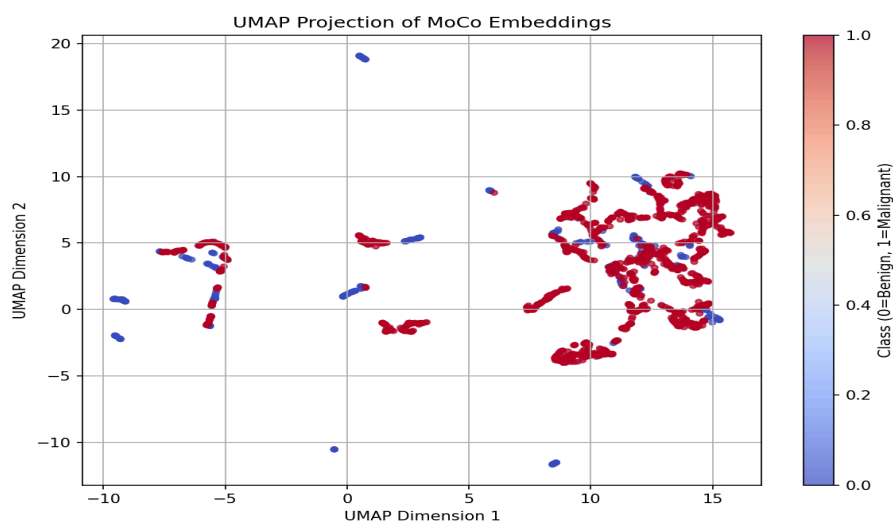
En este caso, los instrumentos de recolección de datos que se utilizaran para este trabajo de investigación son artículos académicos sobre la implementación del modelo MoCo, artículos sobre el Deep learning y publicaciones médicas acerca del diagnóstico de resonancia magnética

## 6. Resultado

El presente proyecto se enfocó en el desarrollo de un modelo para la clasificación de lesiones de cáncer de mama por medio de imágenes de resonancia magnética (MRI) con el objetivo de contribuir a una valoración más rápida y objetiva de cada uno de los diagnósticos. Los resultados obtenidos permiten concluir que la creación de modelos de este tipo puede mejorar mucho esta clase de procesos evaluados por especialistas al igual que pueden contribuir como herramienta complementaria para estos

### 6.1 Separación de embeddings aprendidos con el modelo MoCo

Para esto se generaron embeddings de 2048 dimensiones utilizando el modelo MoCo entrenado sobre el conjunto de validación del dataset Bread DM, donde se busca visualizar de manera las características aprendidas por el modelo al igual que el comportamiento de ambas clases (benigna y maligna) dentro de un espacio de agrupamiento local. Estos embeddings fueron reducidos por UMAP lo que pudo permitir su representación en un plano bidimensional. En el plano podemos observar un dominio evidente de los puntos rojos (lesiones malignas), los cuales tienden a agruparse de manera compacta a diferencia de los puntos azules (lesiones benignas) que a pesar de que casi no tienden a mostrarse mucho en el plano, tienden a tener grupos separados y dispersos. Esto dando a entender que las lesiones malignas presentan patrones visuales más consistentes y fácilmente identificables por el modelo, teniendo un mejor desempeño en la identificación de lesiones malignas y mayor confusión en las benignas.



*Ilustración 2* Mapeo de embeddings del modelo MoCo con UMAP

## 6.2 Evaluación del modelo con KNN

KNN es un método de clasificación supervisado basado en la similitud entre sus datos, para este caso, este modelo se utilizó ya que a base de los embeddings obtenidos en el entrenamiento se puede realizar una clasificación de las imágenes de las lesiones malignas y benignas. Se probaron diferentes valores de K donde se buscaba identificar el número óptimo de vecinos para la clasificación de las lesiones benignas y malignas donde muestran que  $k=1$  y  $k=3$  obtuvieron el mejor desempeño, alcanzando un “Accuracy” del 95.98%, acompañado de otras métricas como precisión, Recall score y F1 Score. Esto mostrando que el modelo tuvo una alta efectividad en cuanto a la detección de lesiones malignas, mientras mantiene una tasa baja de falsos positivos. A medida que el valor de K aumenta, el desempeño va disminuyendo progresivamente, esto debido a la dispersión de la clase benigna en el espacio de embeddings. Este comportamiento muestra que las representaciones aprendidas en base al modelo MoCo genera agrupamientos suficiente definidos como para que un clasificador como KNN pueda lograr resultados sobresalientes

```

--- Evaluando KNN ---
k=1: Acc=0.9598, Prec=0.9636, Rec=0.9876, F1=0.9755
k=3: Acc=0.9598, Prec=0.9608, Rec=0.9907, F1=0.9755
k=5: Acc=0.9296, Prec=0.9324, Rec=0.9845, F1=0.9577
k=7: Acc=0.9146, Prec=0.9186, Rec=0.9814, F1=0.9489
k=9: Acc=0.9146, Prec=0.9162, Rec=0.9845, F1=0.9491

Mejor k=1 con Accuracy=95.98%


```

*Ilustración 3 Porcentajes de evaluación del modelo MoCo con KNN*

## 6.3 Curva ROC – AUC

La curva ROC obtenida permite evaluar la capacidad del modelo para distinguir entre lesiones benignas y malignas a diferentes umbrales de decisión. En la gráfica se observa que la curva asciende rápidamente hacia la esquina superior izquierda lo cual representa un comportamiento ideal en términos de clasificación. El área bajo la curva (AUC) alcanzada fue de “0.915”, lo que indica un buen desempeño frente al modelo. El modelo tuvo un óptimo rendimiento, con un Área

bajo la curva (AUC) de 0,915. Un AUC que se aproxima a 1.0 indica que el sistema tiene una alta probabilidad de adjudicar a una imagen maligna un puntaje superior al de una imagen benigna, lo cual evidencia una distinción efectiva entre ambas clases en el espacio de características. Asimismo, el que la curva permanezca muy por encima de la línea diagonal gris (línea de no discriminación) ratifica que el modelo funciona con un margen significativo por encima del azar y tiene una capacidad real para discriminatorio. Esto es especialmente relevante en aplicaciones médicas, donde es fundamental minimizar los falsos negativos, ya que un diagnóstico maligno no detectado puede tener consecuencias críticas.

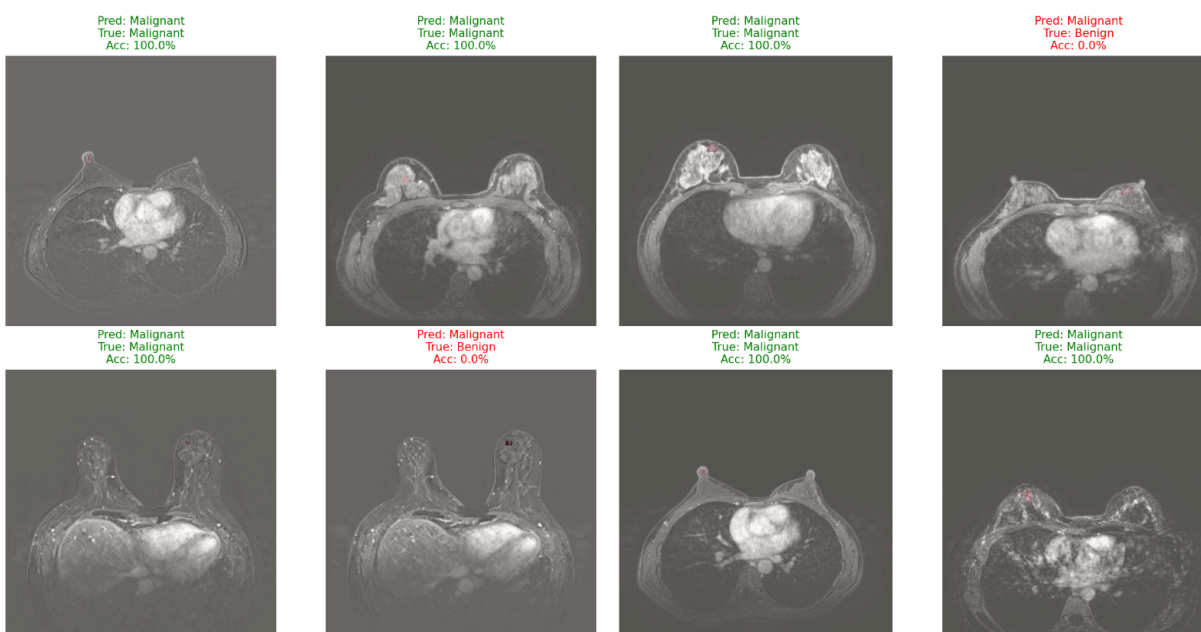


*Ilustración 4. Gráfico de curva ROC-AUC*

#### 6.4 Predicciones en imágenes de MRI

La visualización en el grid de imágenes permite evaluar de forma cualitativa el desempeño del modelo se observa que la mayoría de las lesiones malignas son clasificadas correctamente. Si podemos observar, en las imágenes se pueden visualizar las detecciones por medio de un círculo o una mancha roja la cual consiste en la predicción que el modelo ha realizado en dicha imagen. En este caso el modelo muestra mayor consistencia al identificar patrones asociados a los rasgos de las lesiones malignas, mientras que algunas imágenes benignas son clasificadas como malignas generando falsos positivos. Estos errores se relacionan con la similitud entre ciertos

casos benignos y malignos con la variabilidad de las imágenes.

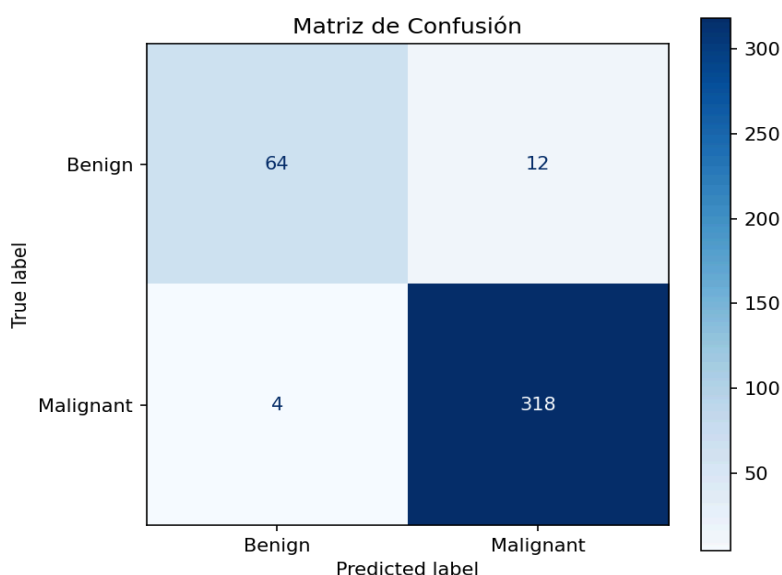


*Ilustración 5. Predicción del modelo MoCo en MRI*

### 6.5 Matriz de confusión del modelo

La matriz de confusión presentada permite evaluar de manera clara el desempeño del modelo MoCo combinado con KNN en la clasificación de lesiones mamarias benignas y malignas a partir de las imágenes MRI. Los resultados de la matriz muestran que 318 casos malignos fueron clasificados como tales de manera adecuada (verdaderos positivos). Se clasificaron adecuadamente 64 casos benignos como benignos (falsos negativos). En total, cuatro lesiones malignas fueron mal clasificadas como benignas (falsos negativos), lo que es clínicamente crítico porque supone el peligro de no detectar una lesión en este tipo de enfermedades.

Se clasificaron como malignas 12 lesiones benignas (falsos positivos), lo que causó una alerta innecesaria, aunque menos grave que un falso negativo. En general, la matriz muestra que el modelo tiene una buena exactitud a la hora de identificar globalmente ambas clases y un alto grado de sensibilidad.



**Ilustración 6.** *Matriz de confusión modelo MoCo*

En comparación con otros trabajos previos de clasificación de lesiones mamarias de MRI, donde se emplean principalmente modelos supervisados basados en CNN con regiones de interés segmentadas manualmente, los resultados obtenidos en el desarrollo de este proyecto muestran un rendimiento competitivo utilizando un enfoque auto supervisado. Sin embargo, los resultados también evidencian un desbalance en la representación interna del modelo, reflejado en el dominio de la clase maligna en el espacio UMAP y el bajo número de falsos negativos en la matriz de confusión. Aunque clínicamente es favorable minimizar falsos negativos, este comportamiento podría indicar que el modelo tiende a priorizar características asociadas a lesiones malignas, afectando la correcta identificación de casos benignos. Dentro del estudio de Xiaoming Zhao, donde utilizan máscaras de segmentación para determinar los distintos tipos de diagnósticos estos muestran unos resultados muy favorables. “Específicamente, LG-CAFN logró la mayor precisión (88,20%, 83,93%) y valor de AUC (0,9154,0,8826) en ambos grupos de experimentos. Se realizan experimentos exhaustivos para presentar líneas de base sólidas basadas en varias segmentaciones de imágenes típicas y algoritmos de clasificación.” (Zhao, 2023). Por tanto, aunque los resultados tengan un margen de precisión alto, solo los está determinando a favor de una sola clase lo cual refleja un desbalance a la hora de determinar el diagnóstico, aún se requiere explorar estrategias para darle un balance a ambas clases e integrar métodos de evaluación tanto en métricas como otros tipos de modelos para poder tener una mejor

clasificación en cuanto a este tipo de diagnóstico

## 7. Conclusiones

El desarrollo de este proyecto permitió demostrar que el uso de técnicas de aprendizaje autosupervisado, específicamente el uso del modelo MoCo (Momentum contrast) constituye una alternativa efectiva para la clasificación de lesiones mamarias determinadas por MRI, incluso si en el caso donde la disponibilidad de este tipo de anotaciones es limitada

A partir del entrenamiento del modelo, se lograron obtener representaciones discriminatorias de las imágenes que facilitaron la separación entre lesiones benignas y malignas sin recurrir a métodos de segmentación o extracción manual de regiones de interés

Los resultados con KNN demostraron un desempeño sobresaliente, alcanzando una precisión del 95.98% un F1- score de 97.5% y un AUC de 0.915, lo que son cifras comparables a estudios previos en base a las investigaciones hechas sobre este tipo de modelos de clasificación. La matriz de confusión evidenció una alta capacidad para detectar correctamente lesiones malignas reduciendo los falsos negativos y fortaleciendo la confiabilidad del diagnóstico temprano, caso muy contrario a las lesiones benignas donde se evidencia un bajo número de casos a favor de las lesiones benignas mostrando un desbalance entre ambas clases. La visualización mediante UMAP permitió validar la capacidad del modelo para agrupar los diferentes grupos de lesiones benignas y malignas, confirmando la calidad de las representaciones aprendidas y mostrando la división entre cada una de estas clases. Sin embargo, al momento de mostrar este tipo de clases se vio un gran dominio de la clase maligna lo que implica la necesidad de darle una mejora al modelo de clasificación y continuar explorando estrategias de balance de clases

El enfoque de este proyecto puede servir como base para futuros desarrollos en diagnóstico asistido por pensamiento computacional en Colombia y países con recursos similares, contribuyendo al avance de herramientas de apoyo clínico y al mismo tiempo buscando reducir la dependencia del criterio subjetivo de especialistas y del proceso manual de anotación, proponiendo una alternativa viable y estable.

## 8. Recomendaciones

A partir del desarrollo del proyecto y de los resultados obtenidos, se identificaron aspectos que pueden ser mejorados y que representan oportunidades para ampliar el alcance de esta investigación. Por lo tanto, se recomienda ajustar estrategias de entrenamiento contrastivo, incluyendo variaciones como “SimCLR”, o “MoCo v3” para comparar su efecto en la separación de las clases malignas y benignas. Dentro de esto también esta optimizar el proceso de extracción de embeddings incorporando técnicas de selección de características o realizarlo por medio de regiones de interés para tomar las características y así realizar un análisis más profundo de las imágenes También, evaluar el impacto de del desbalance de ambas clases incorporando validación cruzada para obtener una evaluación más robusta del rendimiento del modelo

Como nuevas líneas de trabajo se recomienda explorar la clasificación multicategoría para aportar un mayor impacto al proyecto donde las predicciones puedan estar de este modo balanceadas y puedan apoyar a los especialistas en el diagnóstico de las lesiones

Para llevar esto a un trabajo futuro se recomienda desarrollar trabajos posteriores donde se pueda evaluar el modelo en entornos reales con especialistas clínicos. También, implementar una aplicación o un sistema web que permita el uso del modelo en tiempo real como herramienta de apoyo diagnóstico

## 9. Referencias bibliográficas

- Castellote Huguet, M. P. (6 de October de 2021). Obtenido de Universitat Politecnica De Valencia:  
<https://riunet.upv.es/entities/publication/661343f5-4ce8-4dca-91d2-c57c2e22da1f>
- Durán López, L. (3 de September de 2019). Obtenido de Universidad de Sevilla:  
<https://idus.us.es/items/aa0a5ff8-a247-4d46-a34e-119019cac5c4>
- J. Fernández -Parra, M. C. (28 de December de 2010). *Clasificación radiológica y manejo de las lesiones mamarias*. Obtenido de  
<https://www.sciencedirect.com/science/article/abs/pii/S0210573X10001231>
- Mika Ami, E. H. (25 de September de 2021). *Springer Nature Link*. Obtenido de El aprendizaje contrastivo autosupervisado en múltiples modalidades mamarias mejora el rendimiento de la clasificación: [https://link.springer.com/chapter/10.1007/978-3-030-87602-9\\_11](https://link.springer.com/chapter/10.1007/978-3-030-87602-9_11)
- He, K., Fan, H., Wu, Y., Xie, S., & Girshick, R. (2020). Momentum contrast for unsupervised visual representation learning. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 9729-9738).
- Ramírez, M. E. (2017). *Revista Médica Sinergia*. Obtenido de  
<https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=81708>
- Roncales, I. I. (2024). *Universitat Politècnica de Valencia*. Obtenido de  
<https://riunet.upv.es/server/api/core/bitstreams/19b7adc2-ddfd-4d65-a24f-47c2ad3efbc2/content>
- Tsuneki, M. (19 de September de 2022). *ScienceDirect*. Obtenido de Modelos de aprendizaje profundo en el análisis de imágenes médicas:  
<https://www.sciencedirect.com/science/article/abs/pii/S1349007922000500>
- Xianqi Meng, H. Y. (12 de March de 2025). *ScienceDirect*. Obtenido de A self-supervised representation learning paradigm with global content perception and peritumoral context restoration for MRI breast tumor segmentation:  
<https://www.sciencedirect.com/science/article/abs/pii/S174680942500268X>
- Zhao, X. (September de 2023). *BreastDM: A DCE-MRI dataset for breast tumor image segmentation and classification*. Obtenido de  
<https://www.sciencedirect.com/science/article/abs/pii/S0010482523007205>