

Universidad Autónoma de Baja California

FACULTAD DE INGENIERÍA



“Clasificación de Lesiones Intravascular en Imágenes de Ultrasonido Utilizando Algoritmos de Aprendizaje Automático”

TESIS PARA OBTENER EL GRADO DE:
MAESTRÍA EN INGENIERÍA

PRESENTA

Cristian David García Verdugo

DIRECTOR

Dra. Wendy Flores Fuentes

CODIRECTOR

Dr. Eder Alejandro Rodríguez Martínez

Mexicali, B.C. a 12 de enero de 2025

AGRADECIMIENTOS

Quiero expresar mi más profundo agradecimiento a mis padres, quienes han sido el pilar fundamental en mi vida y en este camino académico. Su amor incondicional, paciencia y constante apoyo me han dado la fuerza para superar cada obstáculo. Gracias por creer en mí y por acompañarme en cada paso de este proyecto; no podría haberlo logrado sin ustedes.

A mi amiga, gracias por ser esa mano amiga en los momentos más desafiantes, por tu comprensión, tus palabras de aliento y por estar siempre presente. Tu apoyo y cariño han sido una fuente inagotable de motivación y alegría durante todo este proceso.

Quiero también expresar mi gratitud a los miembros del Comité de Tesis. Su orientación, conocimientos y dedicación fueron fundamentales para dar forma a esta investigación. Agradezco profundamente el tiempo y esfuerzo que invirtieron en guiarme hacia la culminación de este trabajo.

Finalmente, agradezco al Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT) por el apoyo brindado. Su respaldo fue esencial para hacer realidad este proyecto.

A todos ustedes, gracias por confiar en mí y por ser parte de este logro.

DEDICATORIA

A mis padres, quienes han sido mi mayor fuente de fortaleza y guía en cada etapa de mi vida.

Desde que era niño, su amor incondicional, sacrificios y enseñanzas me han mostrado el verdadero significado de la dedicación y el compromiso. Me han inculcado la importancia de la educación y el valor de nunca rendirme ante los desafíos. Todo lo que soy y lo que he logrado se lo debo a ustedes, por su fe inquebrantable en mí, incluso en los momentos en los que dudé de mí mismo. Este logro es tanto suyo como mío.

A mi hermano, mi compañero de vida, con quien he compartido alegrías, dificultades y sueños. Gracias por estar siempre a mi lado, ofreciéndome tu amistad, consejos y apoyo incondicional.

Tu compañía ha sido un refugio en los momentos de incertidumbre, y tu ejemplo me ha motivado a seguir esforzándome cada día.

A mi amiga, quien ha estado a mi lado en cada paso de este arduo camino. Gracias por tu paciencia, tu comprensión y por compartir conmigo tus palabras de aliento en los momentos en que más las necesitaba. Has sido mi pilar y mi motivación constante para seguir adelante, incluso en las etapas más difíciles. Este logro no sería posible sin ti, y te lo dedico con todo mi corazón.

A todos ustedes, por su amor, apoyo y por creer en mí. Este sueño cumplido es un reflejo del amor y la dedicación que he recibido de cada uno de ustedes. Hoy, este logro es compartido y celebrado en familia.

RESUMEN

La tesis titulada “*Clasificación de Lesiones Intravascular en Imágenes de Ultrasonido Utilizando Algoritmos de Aprendizaje Automático*” aborda el desarrollo de un sistema automatizado para la identificación y clasificación de lesiones intravasculares en imágenes obtenidas mediante ultrasonido intravascular (IVUS). Este trabajo responde a la necesidad de superar las limitaciones de los métodos manuales y tradicionales, que suelen ser imprecisos y dependientes de la experiencia del especialista, en procedimientos críticos como la angioplastia coronaria.

El ultrasonido intravascular es una herramienta ampliamente utilizada en la cardiología intervencionista para obtener imágenes detalladas de las arterias coronarias. Este método complementa las angiografías tradicionales al ofrecer información precisa sobre la composición y características de las placas ateroscleróticas, las cuales son factores clave para predecir y prevenir eventos cardiovasculares adversos, como el síndrome coronario agudo y la muerte súbita cardíaca. Sin embargo, la interpretación de estas imágenes es compleja y propensa a errores, lo que subraya la importancia de sistemas que automaticen esta tarea.

La metodología desarrollada en este trabajo integra técnicas avanzadas de visión por computadora y algoritmos de aprendizaje automático para procesar imágenes IVUS. El flujo de trabajo incluye el preprocesamiento de las imágenes, normalización, reducción de ruido mediante filtros gaussianos, y la extracción de los histogramas de intensidad. Estas características se utilizan posteriormente para entrenar y evaluar varios modelos de clasificación, incluyendo máquinas de soporte vectorial (support vector machine, SVM por sus siglas en inglés), bosques aleatorios (Random Forest), algoritmo de Naive Bayes y vecinos cercanos (k-Nearest Neighbors, k-NN por sus siglas en inglés).

Los resultados obtenidos en la experimentación demuestran que los algoritmos propuestos son efectivos en la clasificación automática de placas ateroscleróticas, alcanzando altos niveles de precisión en comparación con evaluaciones manuales realizadas por expertos. Adicionalmente, se desarrolló una interfaz de usuario que permite a los profesionales de la salud cargar imágenes IVUS, visualizar los resultados del análisis y realizar ajustes manuales si es necesario, mejorando así la utilidad práctica del sistema.

La investigación no solo contribuye a optimizar la toma de decisiones clínicas en la angioplastia coronaria, sino que también abre nuevas posibilidades para el uso del aprendizaje automático en la medicina personalizada y la prevención de enfermedades cardiovasculares. Además, establece una base sólida para futuros estudios que integren múltiples modalidades de imagen, como la combinación de IVUS con tomografía de coherencia óptica (OCT), y el desarrollo de modelos más robustos capaces de manejar imágenes ruidosas o incompletas.

En conclusión, este trabajo representa un avance significativo hacia la automatización del diagnóstico intravascular, ofreciendo una herramienta que mejora la precisión, consistencia y eficiencia del análisis médico, lo cual puede tener un impacto directo en la calidad de vida y la supervivencia de los pacientes si se implementa en la práctica clínica.

ÍNDICE

AGRADECIMIENTOS	I
DEDICATORIA	II
RESUMEN	III
1. INTRODUCCIÓN	1
1.1. Antecedentes	2
1.1.1. Historia y Desarrollo	2
1.1.2. Evolución Tecnológica	2
2. PROPÓSITO DE LA INVESTIGACIÓN	4
2.1. Planteamiento Del Problema	4
2.2. Justificación	5
2.3. Hipótesis	5
2.4. Objetivos de la investigación	6
2.4.1. Objetivo General	6
2.4.2. Objetivos Específicos	6
3. INVESTIGACIÓN DEL ESTADO DEL ARTE	7
3.1. Aplicación de la Visión por Computadora, Ultrasonido Intravascular y Aprendizaje Automático en la Detección de Placas Ateroscleróticas	7
3.2. Ultrasonido Intravascular (IVUS) y su Aplicación en Cardiología	7
3.3. Histología Virtual (VH-IVUS) y Caracterización de Placas	8
3.4. Avances en la Segmentación de Imágenes Médicas	8
3.5. Aprendizaje Automático en la Detección de Placas Ateroscleróticas	8
3.6. Visión por Computadora y su Rol en la Segmentación Automatizada	9
3.7. Comparación entre Tecnologías de Imagen: IVUS, OCT y MRI	9
3.8. Desafíos y Oportunidades Futuras en el Diagnóstico Automatizado	10
3.9. Perspectivas Futuras	10
4. FUNDAMENTOS TEÓRICOS	11
4.1. Estructura de un Vaso Sanguíneo	11
4.1.1. Estructura General de los Vasos Sanguíneos	11
4.1.2. Diferencias entre Arterias, Venas y Capilares	13
4.1.3. Relevancia Clínica de las Capas Vasculares	14

4.2.	Angioplastia Coronaria	14
4.2.1.	Procedimiento	14
4.2.2.	Resultados y Pronóstico	14
4.2.3.	Proyecciones Angiográficas	15
4.2.4.	Proyección con Ultrasonido Intravascular	17
4.3.	Utilización de Ultrasonido Intravascular	17
4.4.	Procesamiento de Imágenes y su Aplicación a Ultrasonidos Intravasculares	20
4.5.	Manipulación Básica de Imágenes con PIL	21
4.5.1.	Visualización de Imágenes con Matplotlib	22
4.5.2.	Procesamiento Matemático de Imágenes con NumPy	22
4.5.3.	Ecuilización de Histograma	23
4.5.4.	Reducción de Ruido con SciPy	23
4.5.5.	Detección de Bordos y Gradientes	24
4.5.6.	Flujo de Trabajo Aplicado a Imágenes IVUS	25
4.6.	CLASIFICADORES DE APRENDIZAJE AUTOMÁTICO PARA IVUS	26
4.6.1.	Máquinas de Soporte Vectorial	26
4.6.2.	Bosques Aleatorios	27
4.6.3.	Ingenuo Bayes	28
4.6.4.	Vecinos Cercanos	29
5.	METODOLOGÍA DE LA EXPERIMENTACIÓN	31
5.1.	Extracción de Imágenes de Ultrasonido Intravascular de Archivos DICOM	31
5.2.	Identificación de Imágenes	32
5.3.	Normalización de Imágenes	33
5.4.	Entorno de Desarrollo	34
5.5.	Extracción de Características	34
5.5.1.	Importación y Preprocesamiento de Imágenes	35
5.5.2.	Cálculo del Histograma	35
5.6.	Clasificación	35
5.6.1.	Máquinas de Soporte Vectorial (SVM)	36
5.6.2.	Bosques Aleatorios (Random Forest)	36
5.6.3.	Ingenuo Bayes (Naive Bayes)	36
5.6.4.	Vecinos Cercanos (k-NN)	37
5.7.	Evaluación	39
5.7.1.	Precisión y Matriz de Confusión	39
5.8.	Interface	39
5.8.1.	Importación de Bibliotecas	39
5.8.2.	Clonación del Repositorio del Modelo	40
5.8.3.	Carga del Modelo y el Escalador	40
5.8.4.	Preprocesamiento y Cálculo del Histograma de la Imagen	41
5.8.5.	Subida y Clasificación de Imágenes	41
6.	RESULTADOS	43
6.1.	Métricas de Evaluación	43
6.2.	Resultados por Modelo	44
6.2.1.	Clasificador SVM	44

ÍNDICE

6.2.2. Clasificador Bosques aleatorios	45
6.2.3. Clasificador Gaussian Ingenuo Bayes	45
6.2.4. Clasificador Vecinos cercanos	46
6.2.5. Interfaz	46
7. CONCLUSIONES	47
REFERENCIAS	51

Índice de Figuras

4.1. Capas arteriales.	13
4.2. Proyección angiográfica de vaso con estenosis.	15
4.3. Proyección angiográfica de vaso sano.	16
4.4. Vaso sano imagen de ultrasonido.	18
4.5. Vaso con placa de calcio imagen de ultrasonido.	19
4.6. Vaso con placa fibrótica imagen de ultrasonido.	19
4.7. Vaso con placa mixta fibrótico, grasa y calcio imagen de ultrasonido.	20
4.8. Ejemplos de procesados con PIL.	22
4.9. Ejemplos de plotting con Matplotlib.	23
4.10. Transformaciones de niveles de gris.	24
4.11. ejemplo de desenfoque gaussiano utilizando el módulo <code>scipy.ndimage.filters</code>	24
4.12. Ejemplo de cálculo de derivadas de imágenes utilizando filtros de derivadas de Sobel.	25
4.13. Clasificación de dos clases mediante SVM en 2D y 3D.	27
4.14. Esquema de ensamble utilizando árboles de decisión.	28
4.15. Clasificación de imágenes utilizando el modelo de Naive Bayes.	29
4.16. Representación gráfica de un ejemplo de clasificación utilizando el algoritmo de vecinos cercanos.	30
5.1. Equipo de adquisición de imágenes Polaris.	32
5.2. Software HOROS.	32
5.3. Imagen original.	33
5.4. Imagen normalizada.	34
5.5. Histogramas de intensidad.	35
5.6. Matriz de confusión para SVM.	36
5.7. Matriz de confusión para RF.	37
5.8. Matriz de confusión para Ingenuo Bayes.	38
5.9. Matriz de confusión para vecinos cercanos.	38
6.1. Resultados de la interfaz cargada con el algoritmo de vecinos cercanos con pesos por distancias.	46

Índice de Tablas

6.1. Métricas de desempeño de los modelos, con los mejores resultados destacados con un asterisco(*).	43
---	----

CAPÍTULO 1

INTRODUCCIÓN

La muerte súbita cardíaca (MSC) es definida como un colapso o paro cardíaco súbito, a menudo secundario a arritmias cardíacas sostenidas [1]. La MSC representa una de las principales causas de mortalidad en el mundo [2][3]. Esta puede ocurrir tanto en personas con enfermedad cardíaca previa como en aquellas sin antecedentes de esta patología [4]. Fisiológicamente, la MSC se desencadena cuando el corazón deja de bombear sangre al cerebro y a los órganos vitales del cuerpo, lo que conduce a la muerte si no se interviene rápidamente, idealmente en minutos. Según la Organización Mundial de la Salud (OMS), alrededor de 17.9 millones de personas fallecen cada año a causa de enfermedades cardiovasculares, lo que equivale al 31 % de todas las muertes globales [2]. Dentro de este grupo, se estima que entre el 40 % y el 50 % de las muertes están relacionadas con la MSC [3].

Es importante destacar que, aunque la muerte súbita cardíaca suele presentarse de manera inesperada, algunos pacientes pueden experimentar síntomas previos como dolor torácico, disnea o palpitaciones. Sin embargo, para que el diagnóstico sea de MSC, dichos síntomas deben manifestarse en menos de una hora antes del colapso. Estudios muestran que más del 70 % de los casos de MSC son atribuibles a cardiopatía isquémica, y una gran mayoría de estos eventos ocurren a nivel extrahospitalario, lo que dificulta el tratamiento oportuno [4]. Otras causas menos comunes incluyen el accidente cerebrovascular (ACV), la rotura de aneurismas aórticos y la tromboembolia pulmonar masiva [2].

En este contexto, uno de los procedimientos clave para prevenir episodios graves relacionados con la cardiopatía isquémica, como el infarto de miocardio y la MSC, es la angioplastia coronaria. La angioplastia es una intervención terapéutica mínimamente invasiva que se utiliza para abrir arterias coronarias obstruidas o estrechadas, con el objetivo de restablecer el flujo sanguíneo hacia el músculo cardíaco [3]. Según datos de la American Heart Association (AHA), solo en Estados Unidos, se realizan más de 1 millón de angioplastias al año [5], de las cuales aproximadamente el 70 % son procedimientos de emergencia destinados a tratar infartos agudos de miocardio. A nivel global, se estima que más de 4 millones de angioplastias son realizadas anualmente [3].

La técnica estándar de la angioplastia coronaria consiste en insertar un catéter con un pequeño balón en la punta a través de la arteria femoral o radial. Este balón se infla en el sitio de la obstrucción arterial para comprimir la placa intravascular contra la pared del vaso, permitiendo así que la sangre fluya nuevamente. En muchos casos, se coloca un stent (una malla metálica) en el sitio tratado para mantener la arteria abierta de manera permanente [5]. Aunque la angioplastia ha demostrado ser eficaz, la precisión en la identificación de la placa intravascular y en

la medición del diámetro del vaso sigue siendo un reto crítico [4].

En este estudio, se propuso el desarrollo de un algoritmo basado en aprendizaje automático para mejorar la identificación de diferentes tipos de placas intravasculares mediante el uso de procesamiento de imágenes. El objetivo es lograr una mayor precisión en la medición del diámetro del vaso y del lumen, lo que optimizará los procedimientos de angioplastia coronaria y podrá reducir la incidencia de eventos de Síndrome Coronario Agudo (SCA). De acuerdo con el Registro Nacional de Angioplastias en España, la tasa de éxito de este procedimiento es superior al 95 %, pero todavía existen complicaciones postoperatorias en un pequeño porcentaje de pacientes, lo que subraya la necesidad de innovaciones tecnológicas que minimicen estos riesgos [4]:

- Error en la identificación de placas intravasculares.
- Mediciones inexactas del diámetro del vaso y del lumen.
- Subestimación de características de alto riesgo en las placas vulnerables.

Para validar la efectividad del algoritmo propuesto, se utilizó una base de datos de pacientes sometidos a angioplastias coronarias convencionales, con asistencia de ultrasonido intravascular, lo que permitió realizar comparaciones precisas en cuanto a la detección y caracterización de la placa intravascular. Este enfoque busca no solo mejorar los resultados clínicos en pacientes que requieren angioplastias, sino también contribuir a la prevención y reducción de la mortalidad asociada a la muerte súbita cardíaca, permitiendo intervenciones más precisas y oportunas.

1.1. Antecedentes

1.1.1. Historia y Desarrollo

La angioplastia coronaria, también llamada o conocida como intervención coronaria percutánea (ICP), es un procedimiento que tiene como objetivo restaurar el flujo sanguíneo al corazón al abrir arterias coronarias obstruidas o estrechadas. Dicho procedimiento es utilizado para tratar la enfermedad arterial coronaria y aliviar los síntomas de la angina de pecho o inclusive para mejorar el pronóstico en pacientes con infarto agudo al miocardio (IAM) [6].

En 1970 se dio inicio al desarrollo de la angioplastia coronaria a manos del cardiólogo suizo Andreas Grüntzing, el cual realizó la primera angioplastia coronaria con balón en un paciente humano en 1977, iniciando una nueva era en el tratamiento de la enfermedad de las arterias coronarias (EAC) [6].

1.1.2. Evolución Tecnológica

La tecnología ha avanzado significativamente desde la implementación de balones para dilatar las arterias lesionadas. En 1980 se mejoraron los resultados para la reducción de reestenosis coronarias al implementar stents metálicos o prótesis arteriales a la arteria a tratar. Los stents liberadores de fármacos fueron desarrollados en la década de los 2000 (DES, por sus siglas en inglés), los cuales liberan medicamentos para prevenir la reestenosis arterial [7].

Un estudio comparativo llevado a cabo por [8] demostró la superioridad de los stents metálicos sobre la angioplastia con balón, teniendo como resultados una menor tasa de reestenosis y mejores pronósticos a largo plazo. En [7] analizaron los resultados a tres años de la implementación de stents liberadores de fármacos con everolimus, dando resultados positivos, eficaces y con mayor seguridad en la práctica clínica.

CAPÍTULO 2

PROPÓSITO DE LA INVESTIGACIÓN

2.1. Planteamiento Del Problema

La angioplastia coronaria es un procedimiento clave en el tratamiento de enfermedades cardíacas, pero enfrenta una limitación significativa en cuanto a la visualización precisa y completa de las lesiones en los vasos sanguíneos. Esta limitación puede dificultar la evaluación exacta y el tratamiento adecuado de las enfermedades coronarias, lo que puede llevar a decisiones clínicas menos efectivas [9].

Diversos estudios han demostrado que entre el 10 % y el 20 % de los procedimientos de angioplastia coronaria presentan dificultades debido a la insuficiente visualización de las lesiones [10]. Además, la variabilidad en la interpretación de las imágenes puede tener un impacto significativo en los resultados clínicos. Investigaciones indican que la precisión diagnóstica puede variar hasta un 30 % entre diferentes especialistas [11].

Para abordar esta limitación, se ha propuesto el uso del ultrasonido intravascular (IVUS, por sus siglas en inglés) como una herramienta complementaria que ofrece una visualización más detallada y precisa del interior de los vasos sanguíneos [12]. El IVUS proporciona imágenes en tiempo real que permiten una mejor evaluación de las dimensiones y características de las lesiones, mejorando así la capacidad del médico para realizar diagnósticos más precisos. Sin embargo, la interpretación de estas imágenes requiere una alta especialización y experiencia, lo que introduce una variabilidad significativa en los diagnósticos y tratamientos [13].

Dada esta situación, surge la necesidad de desarrollar herramientas que automaticen la interpretación de las imágenes de IVUS. Un software automatizado que pueda analizar y proporcionar interpretaciones precisas de las imágenes de IVUS podría representar un avance crucial en la asistencia al médico tratante. Este tipo de tecnología tiene el potencial de reducir la carga cognitiva sobre los médicos, mejorar la consistencia en los diagnósticos y tratamientos, y, en última instancia, optimizar los resultados clínicos para los pacientes.

Por lo tanto, la presente tesis se propone explorar el desarrollo de un sistema automatizado de interpretación de imágenes de IVUS, evaluando su efectividad para mejorar la precisión diagnóstica y la calidad del tratamiento en procedimientos de angioplastia coronaria, contribuyendo así a una mejor gestión de las enfermedades cardíacas.

2.2. Justificación

La angioplastia coronaria es un procedimiento crucial en la cardiología para tratar las obstrucciones de las arterias coronarias y mejorar el flujo sanguíneo al corazón. Sin embargo, uno de los desafíos persistentes en este procedimiento es la calidad de las imágenes obtenidas. Las imágenes angiográficas, aunque útiles, a menudo no proporcionan una visualización completamente precisa de las lesiones vasculares. Esto puede llevar a una evaluación inexacta de la severidad y las características de las obstrucciones, lo que afecta la toma de decisiones clínicas y el manejo del paciente [14].

Estudios indican que aproximadamente entre el 15 % y el 20 % de las imágenes angiográficas pueden no reflejar adecuadamente la gravedad de las lesiones, lo que puede resultar en diagnósticos incorrectos y una mayor tasa de complicaciones [15]. Esta imprecisión en la evaluación puede también incrementar la necesidad de procedimientos adicionales o reintervenciones. La variabilidad en la interpretación de las imágenes angiográficas entre diferentes especialistas es otra preocupación significativa. Investigaciones han demostrado que esta variabilidad puede resultar en diferencias de hasta un 30 % en la evaluación de las lesiones, lo cual puede comprometer la precisión del tratamiento [16].

Para superar estas limitaciones, el ultrasonido intravascular (IVUS) ha sido introducido como una herramienta complementaria. El IVUS ofrece una visualización más detallada y directa del interior de los vasos sanguíneos, permitiendo una evaluación más precisa de las lesiones [17]. Sin embargo, a pesar de las ventajas del IVUS, la interpretación de sus imágenes sigue dependiendo en gran medida de la experiencia del médico. Esta dependencia puede introducir variabilidad y errores en el diagnóstico, ya que estudios muestran que la habilidad del médico para interpretar imágenes IVUS puede variar significativamente, afectando la consistencia en los diagnósticos [18].

Dado que la interpretación manual del IVUS sigue siendo susceptible a errores y variabilidad, se hace imperativo desarrollar un software automatizado para analizar estas imágenes. Un sistema automatizado basado en técnicas de procesamiento de imágenes y aprendizaje automático puede proporcionar una interpretación más rápida y precisa, reduciendo la carga cognitiva del médico y mejorando la consistencia de los diagnósticos [19]. Este tipo de tecnología tiene el potencial de mejorar significativamente la precisión diagnóstica y optimizar la toma de decisiones clínicas, al proporcionar una herramienta estandarizada que minimice la variabilidad y mejore la calidad del cuidado del paciente.

En resumen, la justificación para desarrollar un software automatizado para la interpretación de imágenes IVUS radica en la necesidad de superar las limitaciones actuales en la visualización y evaluación de las lesiones coronarias. Esta tecnología podría ofrecer una mejora significativa en la precisión diagnóstica y en la eficiencia del tratamiento, abordando las deficiencias presentes en los métodos actuales.

2.3. Hipótesis

La clasificación automatizada de diferentes tipos de lesiones intravasculares utilizando algoritmos de aprendizaje automático permitirá una identificación más precisa y rápida de las patologías, lo cual mejorará la toma de decisiones clínicas y optimizará el tratamiento para los pacientes, contribuyendo a una reducción de complicaciones y una mejora en los resultados

terapéuticos.

2.4. Objetivos de la investigación

2.4.1. Objetivo General

El objetivo general de esta tesis es diseñar y desarrollar un clasificador que sea capaz de analizar imágenes de ultrasonido intravascular y clasificar automáticamente los diferentes tipos de lesiones. Este clasificador busca mejorar la precisión en la identificación de patologías, optimizando el proceso de diagnóstico y brindando una herramienta eficiente para los profesionales de la salud, facilitando así la toma de decisiones clínicas.

2.4.2. Objetivos Específicos

1. Desarrollar algoritmos de procesamiento de imágenes que puedan identificar y caracterizar automáticamente las estructuras anatómicas y las lesiones coronarias en las imágenes de ultrasonido intravascular, asegurando una alta precisión y consistencia en la detección.
2. Implementar una interfaz de usuario intuitiva que permita a los profesionales de la salud interactuar fácilmente con el clasificador, visualizar las interpretaciones automáticas y, si es necesario, realizar ajustes manuales para mejorar la precisión diagnóstica.
3. Evaluar el desempeño del clasificador mediante estudios clínicos comparativos, analizando la precisión de las interpretaciones automáticas frente a las realizadas por expertos humanos, y medir su impacto en la toma de decisiones clínicas y en los resultados de los pacientes sometidos a angioplastia coronaria.

CAPÍTULO 3

INVESTIGACIÓN DEL ESTADO DEL ARTE

3.1. Aplicación de la Visión por Computadora, Ultrasonido Intravascular y Aprendizaje Automático en la Detección de Placas Ateroscleróticas

En las últimas décadas, el diagnóstico y tratamiento de enfermedades cardiovasculares ha avanzado significativamente gracias a la integración de nuevas tecnologías de imágenes médicas y análisis de datos. En particular, la combinación de ultrasonido intravascular (IVUS), la histología virtual (VH-IVUS), la visión por computadora y el aprendizaje automático han permitido mejorar la precisión en la detección de placas ateroscleróticas y la predicción de eventos cardiovasculares adversos. Este trabajo examina los avances más recientes en estas áreas, destacando las técnicas clave utilizadas para la segmentación y caracterización de las placas, y el impacto que estas innovaciones tienen en la práctica clínica [20],[21].

3.2. Ultrasonido Intravascular (IVUS) y su Aplicación en Cardiología

El ultrasonido intravascular (IVUS) es una técnica que ha sido ampliamente utilizada para la evaluación detallada de las arterias coronarias. IVUS permite obtener imágenes transversales de alta resolución de las paredes arteriales, lo que facilita la identificación y cuantificación de placas ateroscleróticas. Esta técnica ha sido esencial en estudios como el ensayo PROSPECT, que monitoreó a pacientes con síndromes coronarios agudos para evaluar la progresión de la aterosclerosis y predecir eventos cardiovasculares futuros [22]. En dicho estudio, se observó que las características de las placas, como la carga de placa y la morfología, eran factores determinantes en la predicción de eventos adversos, subrayando la importancia de las imágenes IVUS para la evaluación clínica.

Además de su uso clínico, IVUS ha sido fundamental en la investigación básica, proporcionando datos precisos sobre la estructura de las placas y permitiendo el desarrollo de modelos más completos de la aterosclerosis. Sin embargo, uno de los desafíos principales de IVUS es su

resolución limitada en comparación con otras modalidades de imagen, como la tomografía de coherencia óptica (OCT, de sus siglas en inglés). Esto ha motivado la integración de múltiples modalidades de imagen para mejorar la caracterización de las placas [23].

3.3. Histología Virtual (VH-IVUS) y Caracterización de Placas

La histología virtual (VH-IVUS) es una técnica complementaria que utiliza la retrodispersión de frecuencia de radio de las imágenes IVUS para generar mapas codificados por color de la composición de las placas. VH-IVUS ha sido esencial para identificar placas vulnerables, particularmente los fibroateromas de capa fina (TCFA), que son altamente propensos a la ruptura y, por lo tanto, representan un riesgo elevado de eventos cardíacos agudos [21]. La capacidad de VH-IVUS para diferenciar entre los distintos componentes de una placa, como el núcleo necrótico, el calcio y el tejido fibroso, ha mejorado considerablemente la precisión diagnóstica.

A pesar de sus beneficios, VH-IVUS también enfrenta limitaciones, como la dificultad para identificar correctamente la capa fibrosa de las placas debido a la interferencia acústica causada por el calcio. Esto ha llevado a una búsqueda activa de métodos alternativos o complementarios para mejorar la exactitud en la caracterización de las placas. Estudios recientes han explorado la fusión de datos obtenidos de IVUS y OCT para superar estas limitaciones [24], [21].

3.4. Avances en la Segmentación de Imágenes Médicas

La segmentación precisa de imágenes médicas es uno de los pasos más críticos en el análisis de datos obtenidos por IVUS y VH-IVUS. La segmentación implica la separación de las diferentes estructuras anatómicas dentro de la imagen, como las paredes arteriales y las placas. Tradicionalmente, la segmentación se realizaba manualmente, lo que era un proceso lento y propenso a errores humanos. Sin embargo, con la evolución de las técnicas de procesamiento de imágenes y visión por computadora, ahora es posible automatizar gran parte de este proceso [25].

Entre los avances más recientes en la segmentación se encuentran los modelos basados en contornos activos y los algoritmos de agrupamiento, que han demostrado ser eficaces para identificar los bordes de las arterias y las placas. Estos métodos, que incluyen el uso de k-means y agrupamiento difuso (FCM, de sus siglas en inglés), permiten una segmentación más precisa y eficiente, lo que es crucial para el diagnóstico clínico [25]. Además, se han introducido técnicas como el uso de redes neuronales convolucionales (CNN, de sus siglas en inglés) para mejorar la precisión de la segmentación en tiempo real, lo que ha reducido significativamente el tiempo de análisis y ha aumentado la reproducibilidad de los resultados [25].

3.5. Aprendizaje Automático en la Detección de Placas Ateroscleróticas

El aprendizaje automático ha ganado un papel central en el análisis de imágenes médicas, especialmente en la clasificación de placas ateroscleróticas y la predicción de su evolución.

Algoritmos como las máquinas de soporte vectorial (SVM, de sus siglas en inglés) y los árboles de decisión han sido empleados para clasificar las características de las placas identificadas en las imágenes de IVUS. Estos algoritmos son capaces de analizar grandes volúmenes de datos y detectar patrones que no son evidentes a simple vista [3].

Un avance significativo ha sido el desarrollo de redes neuronales profundas, que han mejorado aún más la precisión en la clasificación de placas, superando el 99 % en algunos estudios. Estas redes, entrenadas con grandes conjuntos de datos de imágenes médicas, son capaces de detectar automáticamente las características de alto riesgo en las placas, como la presencia de núcleos necróticos y la delgadez de la capa fibrosa [23]. Sin embargo, el sobreajuste sigue siendo un problema en el desarrollo de estos modelos, especialmente cuando se trabaja con conjuntos de datos limitados. Para mitigar este riesgo, los investigadores han implementado técnicas de regularización y reducción de la dimensionalidad para optimizar el rendimiento de los modelos [3].

3.6. Visión por Computadora y su Rol en la Segmentación Automatizada

La visión por computadora ha sido esencial para mejorar la segmentación automatizada de imágenes de IVUS. Utilizando herramientas como OpenCV y Python, se han desarrollado algoritmos que permiten procesar grandes volúmenes de imágenes médicas y extraer características relevantes para la identificación de placas. Estos algoritmos, basados en técnicas de procesamiento de imágenes como la transformada de contorno y el análisis de textura, permiten una segmentación precisa de las imágenes y una clasificación más eficiente de las placas [20].

Además, el uso de redes neuronales convolucionales en la visión por computadora ha mejorado significativamente la capacidad de los sistemas automatizados para reconocer patrones complejos en las imágenes. Estas redes son capaces de aprender características específicas de las placas ateroscleróticas y segmentar automáticamente las imágenes en regiones significativas, facilitando la evaluación clínica [25]. Las aplicaciones de la visión por computadora en este campo no se limitan a la segmentación; también incluyen la reconstrucción tridimensional de las arterias, lo que ofrece a los médicos una visión más detallada y precisa del estado de las placas [20?].

3.7. Comparación entre Tecnologías de Imagen: IVUS, OCT y MRI

A medida que las tecnologías de imagen han evolucionado, ha surgido una creciente necesidad de combinar diferentes modalidades para mejorar la precisión diagnóstica. IVUS, aunque es muy efectivo para visualizar las estructuras internas de las arterias, tiene una resolución limitada que dificulta la medición precisa de la capa fibrosa de las placas [23]. Por otro lado, la tomografía de coherencia óptica (OCT) ofrece una mayor resolución y permite medir con precisión el grosor de la capa fibrosa, lo que es crucial para identificar placas vulnerables [26, 23].

Estudios recientes han demostrado que la combinación de IVUS y OCT puede proporcionar una caracterización más completa de las placas ateroscleróticas, mejorando la capacidad de

predecir eventos cardíacos adversos. Además, se ha investigado el uso de resonancia magnética (MRI, de sus siglas en inglés) para complementar las imágenes de IVUS y OCT, proporcionando información adicional sobre la composición de las placas y su comportamiento dinámico [27].

3.8. Desafíos y Oportunidades Futuras en el Diagnóstico Automatizado

A pesar de los avances significativos en el uso del aprendizaje automático y la visión por computadora en el análisis de imágenes médicas, todavía existen desafíos importantes. Uno de los principales problemas es la variabilidad en la calidad de las imágenes de IVUS debido a factores como el ruido y la sombra del calcio, que pueden afectar la precisión de los algoritmos de segmentación y clasificación [24]. Esto ha llevado al desarrollo de técnicas avanzadas de preprocesamiento de imágenes, que incluyen la eliminación de ruido y la corrección de sombras, para mejorar la calidad de las imágenes antes del análisis automatizado [24].

Otro desafío es la falta de estandarización en los flujos de trabajo clínicos que utilizan aprendizaje automático. Aunque los algoritmos han demostrado ser efectivos en entornos controlados de investigación, su implementación en la práctica clínica a gran escala sigue siendo limitada debido a la falta de validación externa y a la necesidad de una mayor interoperabilidad con los sistemas clínicos existentes [21]. Las investigaciones futuras deben centrarse en la integración de estos algoritmos en sistemas de atención médica en tiempo real, asegurando que puedan ser utilizados de manera confiable en un entorno clínico.

3.9. Perspectivas Futuras

En resumen, los avances en la integración de tecnologías como el IVUS, la histología virtual, el aprendizaje automático y la visión por computadora han revolucionado la forma en que se diagnostican y tratan las enfermedades cardiovasculares. Estos avances han mejorado significativamente la precisión en la detección y caracterización de placas ateroscleróticas, permitiendo una mejor predicción de eventos cardiovasculares adversos. Sin embargo, aún existen desafíos importantes, como la mejora de la calidad de las imágenes, la estandarización de los flujos de trabajo y la integración de múltiples modalidades de imagen [20][3].

Las futuras investigaciones en este campo deben centrarse en la mejora continua de los algoritmos de aprendizaje automático y en el desarrollo de tecnologías de imagen más avanzadas que puedan proporcionar una visión aún más detallada de la estructura y composición de las placas. La combinación de IVUS con tecnologías emergentes, como la inteligencia artificial y la computación en la nube, promete llevar el diagnóstico cardiovascular a un nuevo nivel, mejorando la precisión y la eficiencia en la práctica clínica [3][20].

CAPÍTULO 4

FUNDAMENTOS TEÓRICOS

4.1. Estructura de un Vaso Sanguíneo

Los vasos sanguíneos son estructuras tubulares que transportan la sangre desde el corazón hacia los tejidos y de regreso al corazón. Están organizados en una red compleja que incluye arterias, venas y capilares, cada uno con funciones específicas para mantener la homeostasis. A continuación se describe las capas estructurales de los vasos sanguíneos, sus características y funciones [28, 29, 30].

4.1.1. Estructura General de los Vasos Sanguíneos

Los vasos sanguíneos están compuestos por tres capas principales, cada una diseñada para cumplir funciones específicas. Estas capas son la íntima, la media y la adventicia como se muestra en la Figura 4.1.

Íntima

La íntima es la capa más interna, en contacto directo con la sangre circulante. Su estructura se compone de:

- Una capa de células endoteliales que forma una barrera selectiva para regular el intercambio de sustancias entre la sangre y el tejido vascular.
- Una lámina basal, que proporciona soporte estructural a las células endoteliales.
- En vasos más grandes, una capa subendotelial de tejido conectivo laxo.

Las funciones que desempeña la parte íntima del vaso son las siguientes:

- Facilitar un flujo sanguíneo suave, gracias a la superficie lisa proporcionada por el endotelio.
- Regular el tono vascular mediante la secreción de sustancias como óxido nítrico (vasodilatador) y endotelina (vasoconstrictor).
- Participar en procesos inflamatorios y de reparación tisular.

Media

La capa media es la más gruesa en las arterias y está formada predominantemente por:

- Músculo liso, responsable de la contracción (vasoconstricción) y relajación (vasodilatación) del vaso.
- Fibras elásticas, que otorgan elasticidad y permiten que las arterias se expandan y vuelvan a su forma original tras cada latido cardíaco.
- En vasos de mayor calibre, como la aorta, está delimitada por una lámina elástica interna y externa.

Las funciones que desempeña la parte media del vaso son las siguientes:

- Mantener la presión arterial al resistir las fuerzas generadas por el flujo sanguíneo.
- Regular el diámetro del vaso, adaptándose a las necesidades metabólicas de los tejidos.

Adventicia

La adventicia es la capa más externa, compuesta por:

- Tejido conectivo denso y laxo, que otorga resistencia y flexibilidad.
- Fibras colágenas y elásticas, que anclan el vaso a los tejidos circundantes.
- Vasa vasorum, pequeños vasos que nutren las paredes de vasos más grandes.
- Nervios vasomotores, que controlan la contracción del músculo liso en la capa media.

Las funciones que desempeña la parte adventicia del vaso son las siguientes:

- Proporcionar soporte estructural al vaso.
- Nutrir las capas externas en vasos de gran calibre.

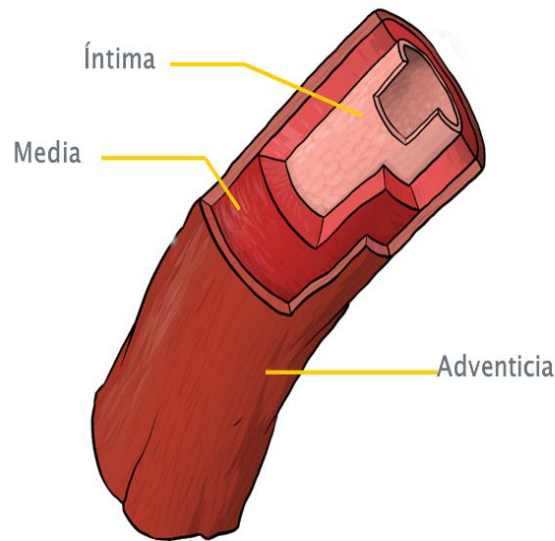


Figura 4.1: Capas arteriales.

4.1.2. Diferencias entre Arterias, Venas y Capilares

Aunque todos los vasos sanguíneos comparten una estructura básica de tres capas, presentan diferencias anatómicas y funcionales específicas:

Arterias

- Tienen una capa media más gruesa y fibras elásticas abundantes, necesarias para resistir la alta presión sanguínea.
- Su lumen es más estrecho y sus paredes son más robustas en comparación con las venas.

Venas

- Poseen una capa media más delgada y menos fibras elásticas, ya que la presión dentro de las venas es significativamente menor.
- Contienen válvulas para prevenir el retroceso de la sangre, especialmente en las extremidades inferiores.

Contienen válvulas para prevenir el retroceso de la sangre, especialmente en las extremidades inferiores.

Capilares

- Solo están compuestos por la íntima, lo que facilita el intercambio de gases, nutrientes y desechos metabólicos entre la sangre y los tejidos.

4.1.3. Relevancia Clínica de las Capas Vasculares

Los cambios estructurales y funcionales en las capas de los vasos pueden llevar a diversas patologías, como:

- **Aterosclerosis:** Engrosamiento de la íntima debido a la acumulación de lípidos y células inflamatorias.
- **Hipertensión arterial:** Aumento de la presión sanguínea relacionado con alteraciones en la capa media, como hipertrofia del músculo liso.
- **Aneurismas:** Dilataciones patológicas asociadas a debilidades en la media o la adventicia.

4.2. Angioplastia Coronaria

4.2.1. Procedimiento

Varios pasos importantes deben tomarse en cuenta para los procedimientos de angioplastia coronaria. En primer lugar, obtener acceso vascular a través de una arteria; por lo general, se utiliza la arteria radial, arteria braquial o la arteria femoral. Después, introducir el catéter guía recorriendo toda la arteria hasta llegar al punto de las coronarias, donde se realiza el procedimiento de angiografía para visualizar algún tipo de lesión. Por último, inflar un balón para predilatar la lesión en el sitio de estenosis y posterior a implantar un stent para lograr apoyar a que la arteria se mantenga abierta [31].

Los escenarios clínicos para angioplastia coronaria son los siguientes:

- **Angina de pecho estable:** Para aliviar los síntomas en pacientes que no responden adecuadamente a la terapia médica.
- **Síndrome coronario agudo (SCA):** Incluyendo el infarto agudo de miocardio con elevación del ST (STEMI) y sin elevación del ST (NSTEMI), donde la intervención rápida puede salvar vidas.
- **Alto riesgo de eventos cardiovasculares:** Pacientes con estenosis significativas detectadas por angiografía que presentan un alto riesgo de eventos cardiovasculares [31].

4.2.2. Resultados y Pronóstico

La efectividad de los procedimientos de angioplastia coronaria para aliviar los síntomas de angina y mejorar la calidad de vida de los pacientes ha sido muy eficaz. La intervención rápida en el contexto de un infarto agudo al miocardio, puede reducir significativamente las complicaciones a largo plazo y la mortalidad.

En [32] realizaron un estudio comparativo entre stents liberadores de everolimus y la cirugía de bypass para la enfermedad del tronco principal izquierdo, demostrando que ambos enfoques tienen resultados comparables en términos de mortalidad y eventos adversos. Además, en [33] destacaron la importancia de la intervención temprana en pacientes con infarto agudo de miocardio con elevación del ST, subrayando la reducción en la mortalidad y las complicaciones a largo plazo con una intervención oportuna.

4.2.3. Proyecciones Angiográficas

La proyección angiográfica es un procedimiento diagnóstico en el cual se utilizan rayos X y contraste yodado para visualizar las arterias coronarias. Durante este proceso, se introduce un catéter en el sistema arterial hasta llegar al origen de las arterias coronarias, donde se inyecta el medio de contraste. Las imágenes resultantes permiten visualizar la morfología de las arterias (Fig. 4.3) y detectar estrechamientos o estenosis (Fig. 4.2) u otras anomalías en los vasos sanguíneos [34].

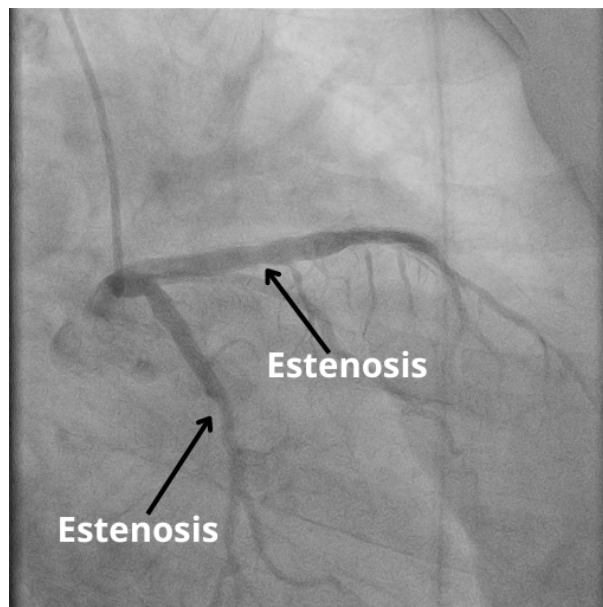


Figura 4.2: Proyección angiográfica de vaso con estenosis.

Ventajas de la Proyección Angiográfica sobre el Ultrasonido Intravascular:

- **Visualización general del sistema arterial:** La angiografía ofrece una visión más amplia de la anatomía vascular en tiempo real, lo que permite una evaluación rápida y eficaz de todas las ramas coronarias. Esto es útil para obtener una visión general de la localización de la stenosis y las estructuras anatómicas.
- **Procedimiento ampliamente utilizado:** Es un método estándar que ha sido utilizado por décadas en cardiología intervencionista, por lo que la experiencia clínica y las guías están bien establecidas.
- **Accesibilidad y familiaridad:** La angiografía es una técnica que está disponible en la mayoría de los hospitales y es el estándar de referencia en la toma de decisiones sobre la necesidad de intervenciones como la angioplastia [35].

Desventajas de la Proyección Angiográfica:

- **Limitación en la evaluación del lumen arterial y la placa aterosclerótica:** Aunque la angiografía puede mostrar las irregularidades de la luz arterial, no permite una evaluación




Figura 4.3: Proyección angiográfica de vaso sano.

detallada del grosor, composición o la extensión de la placa aterosclerótica, lo que limita su capacidad para detectar ciertas lesiones vulnerables.

- **Proyección bidimensional:** La angiografía genera imágenes bidimensionales de estructuras tridimensionales, lo que puede llevar a la subestimación o sobreestimación de la gravedad de la estenosis.
- **Exposición a radiación y contraste:** Los pacientes están expuestos a radiación y a agentes de contraste yodados, lo que puede causar reacciones adversas, especialmente en personas con alergias o insuficiencia renal. La exposición a radiación puede aumentar el riesgo de daño celular y cáncer a largo plazo, El uso de medios de contraste puede inducir nefropatía por contraste, un daño renal agudo, particularmente en pacientes con insuficiencia renal preexistente o diabetes.[36].

Relación entre la Proyección Angiográfica y el Ultrasonido Intravascular (IVUS)

El IVUS es una técnica complementaria a la angiografía que utiliza un pequeño transductor de ultrasonido montado en un catéter para generar imágenes detalladas desde dentro de las arterias coronarias. Las dos técnicas están relacionadas y a menudo se utilizan juntas en la evaluación de enfermedades coronarias [35].

Proyección Angiográfica en la Angioplastia Coronaria:

La angiografía sigue siendo fundamental en la angioplastia coronaria porque permite identificar la localización precisa de las obstrucciones y guiar el procedimiento de intervención (como la colocación de un stent). Sin embargo, la angiografía por sí sola puede no proporcionar suficiente información sobre la severidad de las lesiones. Aquí es donde el IVUS entra en juego, ya

que puede ayudar a optimizar los resultados al ofrecer una mejor visualización de las arterias y garantizar la correcta implantación del stent [34].

En resumen, la angiografía es la técnica de referencia inicial para la planificación de intervenciones coronarias como la angioplastia, mientras que el IVUS proporciona información adicional crítica que puede mejorar la toma de decisiones y los resultados a largo plazo.

4.2.4. Proyección con Ultrasonido Intravascular

A diferencia de la proyección angiográfica, el ultrasonido intravascular no requiere el uso de medio de contraste para generar imágenes. Además, mientras que la angiografía se basa en radiación ionizante para visualizar los vasos sanguíneos, el ultrasonido intravascular utiliza ondas sonoras de alta frecuencia, lo que reduce el riesgo de exposición a la radiación. Asimismo, el ultrasonido intravascular proporciona imágenes transversales y detalladas de la pared arterial, permitiendo una evaluación más precisa de la composición y características de las placas ateroscleróticas. En contraste, la proyección angiográfica ofrece una visión general de la luz del vaso en una sola dimensión, lo que puede limitar la evaluación de las estructuras vasculares complejas.

4.3. Utilización de Ultrasonido Intravascular

La utilización de ultrasonido intravascular (IVUS) en procedimientos de angioplastia coronaria es fundamental por varias razones. Este enfoque ha demostrado mejorar significativamente los resultados de los procedimientos de intervención coronaria percutánea (ICP), ofreciendo ventajas cruciales tanto en la evaluación preoperatoria como en la guía intraoperatoria y la evaluación postoperatoria [37].

En primer lugar, el IVUS permite una visualización detallada y precisa de la anatomía de las arterias coronarias. A diferencia de la angiografía coronaria convencional, que solo muestra la luz del vaso, el IVUS proporciona imágenes transversales del vaso completo, incluyendo la pared arterial. Esto es crucial para la evaluación de la extensión y la composición de la placa aterosclerótica. Estudios han mostrado que el IVUS puede detectar con mayor precisión la gravedad de la estenosis coronaria y la presencia de calcificaciones o trombos que pueden no ser visibles en la angiografía tradicional [37].

Además, el IVUS es esencial en la optimización de la implantación de stents. Este dispositivo permite medir con precisión el diámetro y la longitud del vaso, ayudando a seleccionar el tamaño adecuado del stent. La subexpansión de stents es una causa común de reestenosis y trombosis de stents, y el uso de IVUS ayuda a garantizar una expansión completa y adecuada del stent, minimizando estos riesgos [38]. Un estudio de la Asian Pacific Society of Interventional Cardiology (APSIC) demostró que el uso de IVUS en la implantación de stents se asocia con una reducción significativa en la tasa de revascularización del vaso objetivo y eventos cardíacos adversos mayores [39].

Asimismo, el IVUS es invaluable en la evaluación postoperatoria. Permite una revisión inmediata de la expansión del stent y la aposición a la pared del vaso, asegurando que no haya áreas de mala expansión que puedan predisponer a eventos adversos. La detección temprana de problemas mediante IVUS puede conducir a intervenciones correctivas inmediatas, mejorando los resultados a largo plazo [40].

En resumen, la utilización del ultrasonido intravascular en procedimientos de angioplastia coronaria es de suma importancia debido a su capacidad para proporcionar una evaluación detallada de la anatomía vascular, optimizar la implantación de stents y evaluar el resultado postoperatorio. Estas ventajas se traducen en una mejora significativa en los resultados clínicos y una reducción de las complicaciones asociadas con los procedimientos de intervención coronaria percutánea.

Vaso sano

En una imagen IVUS, un vaso sano muestra capas regulares y bien definidas sin presencia de placas ateroscleróticas. La íntima es fina y brillante, la media es más oscura y uniforme, y la adventicia es brillante y delgada. No hay depósitos de calcio ni engrosamientos que puedan restringir el flujo sanguíneo. Estas características reflejan un flujo sin obstrucciones y una pared arterial flexible y saludable [41], como se ve en la Figura 4.4.




Figura 4.4: Vaso sano imagen de ultrasonido.

Vaso con calcio

En un vaso calcificado, la imagen IVUS revela áreas muy brillantes (hiperecoicas) que corresponden a depósitos de calcio en la pared arterial. Estas áreas suelen producir sombras acústicas debido a la incapacidad del ultrasonido para penetrar el calcio, lo que puede ocultar partes de las capas más profundas del vaso. Esta condición endurece las arterias, afectando su capacidad de expansión [41], como se ve en la Figura 4.5.

Vaso fibrótico

Un vaso fibrótico muestra un engrosamiento en las paredes debido a la acumulación de tejido fibroso. En IVUS, este tejido se observa como zonas brillantes, aunque no tan intensas como los depósitos de calcio. La fibrosis puede aparecer de forma más difusa y no produce las




Figura 4.5: Vaso con placa de calcio imagen de ultrasonido.

sombras acústicas que son típicas del calcio. La acumulación de tejido fibroso puede endurecer las arterias sin causar la rigidez extrema del calcio [41], como se ve en la Figura 4.6.



Figura 4.6: Vaso con placa fibrótica imagen de ultrasonido.

Vaso con placa mixta

En un vaso con placa mixta, se observan áreas heterogéneas que incluyen calcio, fibrosis y lípidos. En IVUS, estas placas se presentan como una combinación de regiones brillantes (calcio y fibrosis) y áreas más oscuras (depósitos de lípidos). La distribución de estos componentes suele ser irregular, lo que puede provocar una obstrucción significativa del flujo sanguíneo. Estas placas complejas requieren atención especial, ya que representan un mayor riesgo de eventos cardiovasculares [41], como se ve en la Figura 4.7.




Figura 4.7: Vaso con placa mixta fibrótica, grasa y calcio imagen de ultrasonido.

4.4. Procesamiento de Imágenes y su Aplicación a Ultrasonidos Intravasculares

El procesamiento de imágenes es una etapa fundamental en la visión por computadora, permitiendo la transformación, mejora y análisis de datos visuales para extraer información útil. Este capítulo explora las técnicas básicas de manipulación de imágenes usando Python, específicamente a través de bibliotecas como PIL, NumPy, Matplotlib y SciPy, con un enfoque particular en su aplicación al análisis de imágenes de ultrasonido intravascular (IVUS).

El objetivo principal es detallar herramientas y métodos que permiten la mejora de imágenes, la eliminación de ruido, la segmentación y la detección de características, estableciendo una base sólida para aplicaciones avanzadas como la reconstrucción tridimensional de vasos sanguíneos o la detección automatizada de patologías [20].

En aplicaciones médicas, como el ultrasonido intravascular (IVUS), estas técnicas se utilizan para analizar las características estructurales de los vasos sanguíneos, detectar anomalías y apoyar en la toma de decisiones clínicas.

La biblioteca Python Imaging Library (PIL) proporciona herramientas para cargar, transformar y guardar imágenes. Estas operaciones son esenciales para preparar imágenes antes de cualquier análisis avanzado [42].

El análisis de imágenes IVUS plantea varios desafíos técnicos, entre ellos:

1. Ruido y artefactos: Las imágenes IVUS suelen estar contaminadas por ruido debido a la naturaleza del ultrasonido y las condiciones de captura.
2. Baja resolución: Esto puede dificultar la detección de detalles finos en las paredes arteriales.
3. Complejidad anatómica: Las estructuras vasculares presentan variabilidad significativa entre pacientes.

4.5. Manipulación Básica de Imágenes con PIL

La biblioteca PIL (Python Imaging Library) es esencial para realizar manipulaciones básicas de imágenes, como cargar, guardar, transformar y ajustar imágenes [43]. Estas operaciones son fundamentales para preparar las imágenes antes de aplicar técnicas avanzadas de análisis como se pueden ver en la Figura 4.8.

Lectura y conversión de imágenes

PIL permite leer imágenes desde diversos formatos (JPEG, PNG, TIFF, entre otros). Una vez cargadas, las imágenes pueden ser convertidas a escala de grises para simplificar el análisis, ya que en muchos casos las variaciones de color no son relevantes.

Ejemplo:

```
from PIL import Image
# Cargar una imagen y convertirla a escala de grises
pil_im = Image.open('empire.jpg').convert('L')
```

En el caso de IVUS, trabajar en escala de grises reduce la dimensionalidad de los datos, permitiendo un procesamiento más eficiente sin pérdida significativa de información relevante.

Transformaciones básicas

PIL también permite realizar operaciones como recortes, rotaciones y redimensionamientos:

- Recorte: Útil para enfocar áreas específicas de interés, como una sección del vaso.
- Rotación: Facilita la alineación de imágenes capturadas en diferentes ángulos.
- Redimensionamiento: Normaliza las dimensiones para un análisis:

```
pil_im = pil_im.resize((256, 256)) \# Redimensionar a 256x256
```

Guardado de imágenes

Las imágenes procesadas pueden ser guardadas en formatos específicos para su posterior análisis, código:

```
pil_im.save('output_image.jpg').
```

Estas operaciones iniciales aseguran que las imágenes estén listas para análisis avanzados, como segmentación o detección de bordes. Por ejemplo, el recorte puede ayudar a enfocar una arteria específica, eliminando artefactos periféricos.



Figura 4.8: Ejemplos de procesados con PIL.

4.5.1. Visualización de Imágenes con Matplotlib

La biblioteca Matplotlib se utiliza para graficar y visualizar imágenes, datos y resultados de procesamiento. Esto es crucial para validar visualmente las operaciones realizadas en las imágenes como se muestra en la Figura 4.9.

Visualización de imágenes

Matplotlib permite cargar y mostrar imágenes directamente como matrices:

```
from pylab import *
Cargar y mostrar una imagen
em = array(Image.open('empire.jpg'))
imshow(em)
show()
```

Superposición de características

Una de las funcionalidades más útiles es la capacidad de superponer puntos, líneas o contornos en la imagen para destacar características importantes:

```
plot([100, 200], [150, 250], 'r*') \# Marcar puntos en rojo
```

En imágenes IVUS, esta funcionalidad permite superponer bordes detectados o áreas segmentadas, ayudando a los especialistas a evaluar visualmente los resultados.

4.5.2. Procesamiento Matemático de Imágenes con NumPy

NumPy es una herramienta clave para representar imágenes como matrices numéricas y aplicar operaciones matemáticas directamente sobre ellas como se ve en la Figura 4.10.

Transformaciones de intensidad

Las transformaciones de intensidad modifican la representación de los píxeles en una imagen, destacando o reduciendo ciertas características. Un ejemplo es la inversión de niveles de

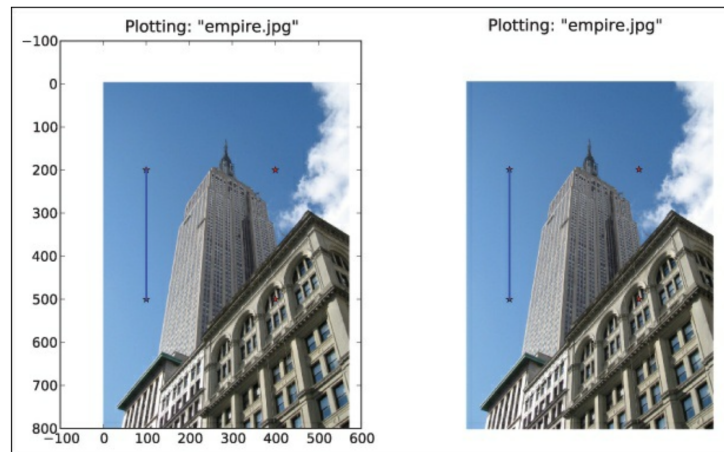


Figura 4.9: Ejemplos de plotting con Matplotlib.

gris:

```
em = array(Image.open('empire.jpg').convert('L'))
inverted_em = 255 - em
```

Análisis estadístico mediante histogramas

Los histogramas son útiles para analizar la distribución de intensidades en una imagen, permitiendo ajustar el contraste o identificar regiones homogéneas:

```
hist(em.flatten(), bins=128)
```

4.5.3. Ecuación de Histograma

La ecuación mejora el contraste distribuyendo uniformemente las intensidades:

```
def histeq(em, nbr_bins=256):
    emhist, bins = histogram(em.flatten(), nbr_bins, density=True)
    cdf = emhist.cumsum()
    cdf = 255 * cdf / cdf[-1]
    em2 = interp(em.flatten(), bins[:-1], cdf)
    return em2.reshape(em.shape)
```

Estas técnicas mejoran la calidad visual de las imágenes IVUS, destacando estructuras como placas ateroscleróticas o paredes arteriales.

4.5.4. Reducción de Ruido con SciPy

El ruido es una de las mayores limitaciones en imágenes médicas como IVUS. SciPy proporciona herramientas avanzadas para eliminar este ruido mediante filtros como el filtro gaussiano



Figura 4.10: Transformaciones de niveles de gris.

como se muestra en la Figura 4.11.

Filtro gaussiano

Este filtro suaviza las imágenes al reducir variaciones rápidas de intensidad: `from scipy.ndimage import filters`

```
em_blurred = filters.gaussian_filter(em, sigma=5)
```



Figura 4.11: ejemplo de desenfoque gaussiano utilizando el módulo `scipy.ndimage.filters`.

Este filtro elimina el ruido granular típico en imágenes IVUS, preservando las estructuras relevantes.

4.5.5. Detección de Bordos y Gradientes

La detección de bordes permite identificar los límites entre diferentes estructuras, como las paredes vasculares. SciPy proporciona herramientas para calcular gradientes, como los filtros Sobel como se muestra en la Figura 4.12.

Cálculo de gradientes

```
los gradientes x e y destacan cambios de intensidad:
emx = filters.sobel(em, axis=0) \# Gradiente en x
emy = filters.sobel(em, axis=1) \# Gradiente en y
magnitudo = sqrt(emx**2 + emy**2) \# Magnitud del gradiente
```




Figura 4.12: Ejemplo de cálculo de derivadas de imágenes utilizando filtros de derivadas de Sobel.

La detección de bordes es esencial para segmentar y analizar las paredes arteriales, proporcionando una base para reconstrucciones tridimensionales.

4.5.6. Flujo de Trabajo Aplicado a Imágenes IVUS

A continuación, se describe un flujo de trabajo típico que combina las técnicas presentadas:

1. Carga y preprocesamiento:
 - Convertir la imagen a escala de grises.
 - Normalizar dimensiones.
2. Reducción de ruido:
 - Aplicar un filtro gaussiano.
3. Segmentación:
 - Identificar regiones de interés mediante umbralización.
4. Detección de bordes:
 - Calcular gradientes para delinear estructuras.
5. Visualización:
 - Superponer bordes detectados sobre la imagen original.

El procesamiento básico de imágenes proporciona una base sólida para el análisis avanzado de imágenes IVUS. Técnicas como la reducción de ruido, la ecualización de histogramas y la detección de bordes son esenciales para mejorar la calidad de las imágenes y extraer información relevante. Estas herramientas no solo optimizan los análisis clínicos, sino que también abren la puerta a aplicaciones automatizadas que mejoran la precisión y eficiencia en el diagnóstico médico.

4.6. CLASIFICADORES DE APRENDIZAJE AUTOMÁTICO PARA IVUS

El aprendizaje automático, también conocido como machine learning, es una rama de la inteligencia artificial que se centra en el desarrollo de sistemas capaces de aprender y mejorar a partir de los datos, sin ser explícitamente programados para cada tarea. Este enfoque permite a las máquinas identificar patrones, realizar predicciones y tomar decisiones basadas en la información proporcionada. Existen numerosos algoritmos en esta área, cada uno diseñado para abordar problemas específicos con distintos niveles de complejidad y precisión. Sin embargo, en nuestro caso particular, hemos decidido concentrarnos en cuatro algoritmos clave debido a su eficacia, versatilidad y amplio uso en diversas aplicaciones. Estos algoritmos son Máquinas de soporte vectorial, Bosques aleatorios, Ingenuo Bayes, y Vecinos cercanos.

4.6.1. Máquinas de Soporte Vectorial

Las Máquinas de Soporte Vectorial son algoritmos de clasificación que buscan la hiperplano óptimo que separa las clases en el espacio de características (o el espacio de características transformado mediante un kernel). El objetivo es maximizar el margen, que es la distancia más corta desde cualquier punto de entrenamiento hasta este hiperplano separador [3].

Detalles clave:

1. Hiperplano óptimo: Se refiere a la línea (en 2D) como se muestra en la Figura 4.13 o el plano (en 3D o más dimensiones) como se muestra en la Figura que divide las clases con el mayor margen posible entre los puntos de datos más cercanos de ambas clases, llamados vectores de soporte.
2. Margen máximo: El algoritmo busca maximizar la distancia entre el hiperplano y los puntos más cercanos de cada clase. Un mayor margen tiende a reducir el error de clasificación en los datos de prueba.
3. Kernel Trick: En los casos en que los datos no son linealmente separables, se puede utilizar una función kernel para transformar los datos a un espacio de mayor dimensión donde sí sean separables. Ejemplos de funciones kernel son polinomial, sigmoide y RBF (radial basis function).

Ventajas:

- Muy efectivo en espacios de alta dimensionalidad.
- Flexible con diferentes kernels.
- Bueno para problemas con margen claro entre clases.

Desventajas:

- Lento para grandes conjuntos de datos.
- Difícil elegir el kernel correcto y sintonizar hiperparámetros.

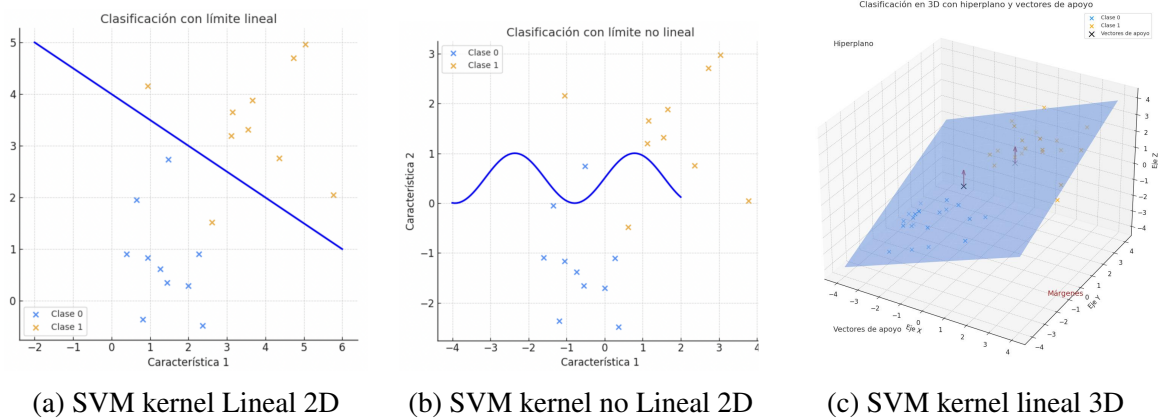


Figura 4.13: Clasificación de dos clases mediante SVM en 2D y 3D.

4.6.2. Bosques Aleatorios

Un Bosque Aleatorio es un algoritmo basado en múltiples árboles de decisión entrenados sobre diferentes subconjuntos de datos y características como se muestra en la Figura 4.14. Se toma una decisión por mayoría de votos entre los árboles para la clasificación (o el promedio para la regresión) [3].

Detalles clave:

1. Bagging (Bootstrap Aggregating): Los árboles son entrenados en diferentes subconjuntos aleatorios de los datos de entrenamiento, lo que reduce la varianza del modelo y ayuda a evitar el sobreajuste.
2. Selección aleatoria de características: En cada división del árbol, solo un subconjunto aleatorio de características se considera, lo que también reduce la correlación entre los árboles.
3. Número de árboles: Generalmente, cuantos más árboles tenga el bosque, mejor será el rendimiento, pero también aumentará el costo computacional .

Ventajas:

- Altamente robusto frente al sobreajuste.
- Maneja bien conjuntos de datos con características importantes no lineales o interacciones complejas.
- Funciona bien incluso con conjuntos de datos desequilibrados y con características faltantes.

Desventajas:

- Pueden ser lentos de entrenar en grandes conjuntos de datos.
- Poca interpretabilidad, ya que los modelos compuestos por muchos árboles son difíciles de interpretar.

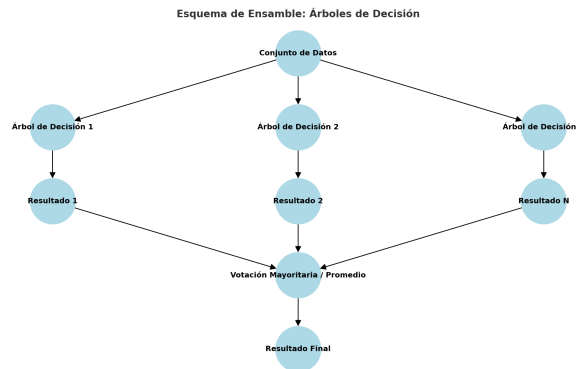


Figura 4.14: Esquema de ensamble utilizando árboles de decisión.

4.6.3. Ingenuo Bayes

El clasificador Ingenuo Bayes es un método probabilístico basado en el Teorema de Bayes con una suposición de independencia fuerte (ingenuo) entre las características. Se utiliza principalmente para la clasificación.

Detalles clave:

1. Teorema de Bayes: Calcula la probabilidad posterior de una clase dada una serie de características observadas [44].

$$P(C|X) = P(X|C) \cdot P(C)/P(X), \tag{4.1}$$

donde C es la clase y X son las características como se muestra en la Figura 4.15.

2. Suposición ingenua de independencia: El algoritmo asume que todas las características son independientes entre sí dentro de cada clase, lo que rara vez es cierto en la práctica, pero aún así el algoritmo puede funcionar bien.
3. Distribuciones: Dependiendo de la naturaleza de las características, existen diferentes variantes como:
 - Bernoulli Ingenuo Bayes: Para características binarias.
 - Multinomial Ingenuo Bayes: Para datos de conteo, como frecuencia de palabras en el procesamiento de lenguaje natural.
 - Gaussian Ingenuo Bayes: Para características continuas que se asumen distribuidas normalmente.

Ventajas:

- Muy rápido de entrenar, incluso con grandes conjuntos de datos.
- Bueno para clasificación de texto, como en filtrado de spam.
- Requiere menos datos para realizar una predicción precisa.

Desventajas:

- La suposición de independencia rara vez es cierta en la vida real, lo que puede limitar el rendimiento del modelo.
- Es sensible a las características irrelevantes o altamente correlacionadas.




Figura 4.15: Clasificación de imágenes utilizando el modelo de Naive Bayes.

4.6.4. Vecinos Cercanos

Vecinos cercanos es un algoritmo basado en la idea de que una observación desconocida pertenece a la clase de la mayoría de sus vecinos más cercanos. El número de vecinos k es un hiperparámetro que define cuántos vecinos se considerarán al realizar la predicción como se muestra en la Figura 4.16.

Detalles clave:

1. Distancia: La clasificación se basa en la distancia entre los puntos en el espacio de características, normalmente utilizando distancias como Euclidiana, Manhattan o Minkowski.
2. Votación por mayoría: Para la clasificación, cada vecino vota por la clase, y la clase con más votos se asigna a la muestra desconocida.
3. Valor de k : Elegir un valor pequeño de k puede hacer que el modelo sea sensible al ruido, mientras que valores grandes pueden sobre-suavizar las predicciones.

Ventajas:

- Simple e intuitivo.
- No requiere entrenamiento, lo que significa que los nuevos datos se pueden clasificar de inmediato.
- Funciona bien con datos de diferentes escalas, siempre y cuando se normalicen.

Desventajas:

- Altamente costoso en términos computacionales para grandes conjuntos de datos, ya que se necesita calcular la distancia a cada punto de entrenamiento.
- Sensible a la escala de los datos, por lo que es importante realizar una normalización previa.
- El valor de k puede ser difícil de ajustar.

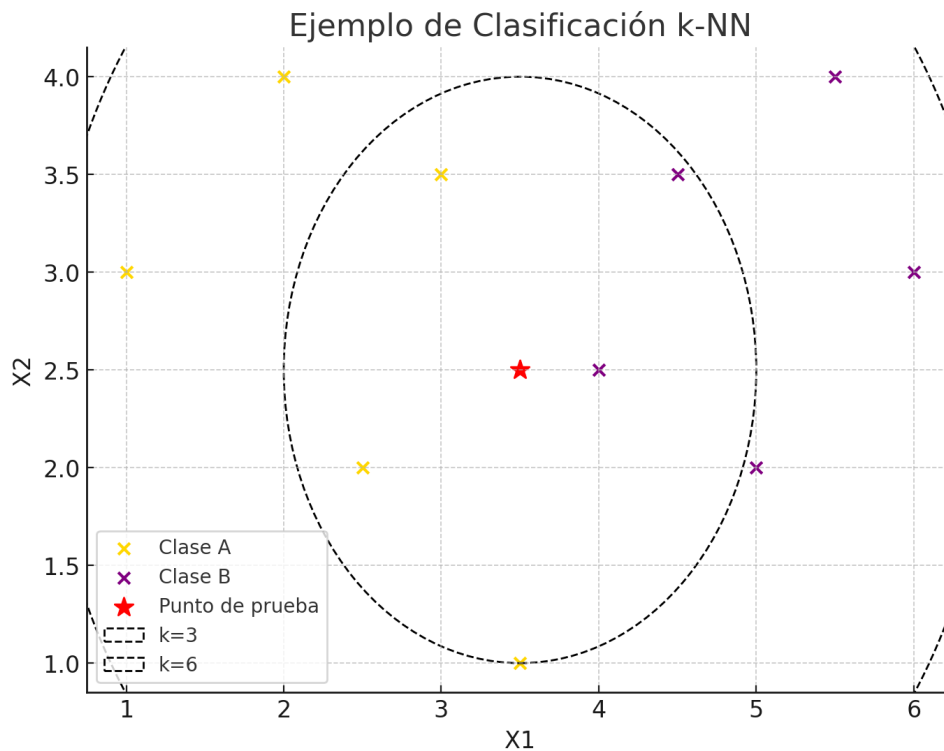


Figura 4.16: Representación gráfica de un ejemplo de clasificación utilizando el algoritmo de vecinos cercanos.

CAPÍTULO 5

METODOLOGÍA DE LA EXPERIMENTACIÓN

5.1. Extracción de Imágenes de Ultrasonido Intravascular de Archivos DICOM

Para la adquisición de imágenes de ultrasonido intravascular, se solicitó y obtuvo el permiso de las Autoridades del Hospital Centro Cardiológico de Mexicali¹. Las imágenes fueron extraídas del historial de estudios realizados con un equipo IVUS modelo Polaris de la marca Boston Scientific, integrado con la versión 1.1 del sistema, ver Figura 5.1. Este equipo cuenta con capacidades avanzadas de retroceso automático a velocidades de 0.5 mm/seg y 1.0 mm/seg, permitiendo obtener imágenes detalladas en cortes transversales, así como reconstrucciones longitudinales mediante la funcionalidad LongView. Además, ofrece una resolución mejorada gracias a su compatibilidad con catéteres OPTICROSS HD de 60 MHz, logrando imágenes de alta definición y profundidad, ideales para el análisis clínico preciso. El sistema también soporta almacenamiento y recuperación digital de estudios en formato DICOM, integrándose perfectamente con sistemas PACS para su análisis y seguimiento clínico.

Este software facilita la descarga de imágenes en escala de grises, a través de archivos en formato DICOM, que es un formato estándar para imágenes médicas, utilizando CDs, ya que el equipo de ultrasonido del hospital no permite la transferencia directa de las grabaciones por otros medios.

Para trabajar con los archivos en formato DICOM se utilizó el software HOROS², una herramienta especializada en la visualización y manejo de imágenes médicas. Este software no solo permitió abrir y visualizar los archivos DICOM, sino que también facilitó la conversión de las imágenes a formatos más accesibles, como .jpg o .png. De este modo, se logró transformar las imágenes en formatos que son fácilmente manejables y compatibles con una variedad de aplicaciones y plataformas, lo que facilitó su análisis y las dejó accesibles para utilizarse para la presente y futuras investigaciones, ver Figura 5.2.

¹<https://centro-cardiologico-deteccion-y-tratamiento.getnetstore.mx/>

²<https://horosproject.org/>




Figura 5.1: Equipo de adquisición de imágenes Polaris.

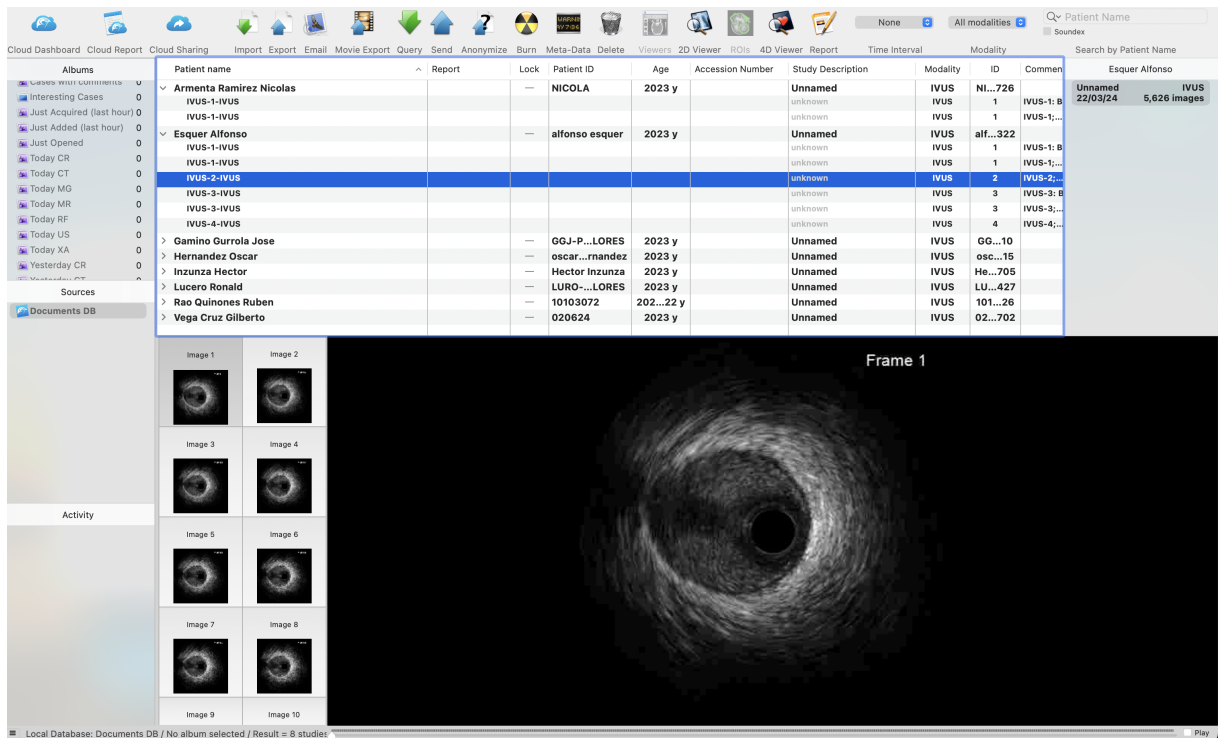


Figura 5.2: Software HOROS.

5.2. Identificación de Imágenes

Después de obtener la autorización y de recopilar los CDs que contenían los estudios de 10 pacientes, los datos se transfirieron a una computadora con sistema operativo macOS sonoma versión 14.5 y software HOROS versión 3.3.6. Esto permitió no solo la visualización de las

grabaciones de manera efectiva, sino también la selección detallada de los “frames” de interés para su análisis posterior.

El proceso de selección de “frames” implicó una cuidadosa identificación de aquellos que mostraran de manera nítida y detallada las diferentes lesiones presentes en los vasos arteriales. Se hizo un esfuerzo consciente por capturar una amplia variedad de imágenes que representaran adecuadamente cada tipo de lesión, con el objetivo de construir una base de datos lo más representativa posible. La cual quedó integrada con 887 cantidad de imágenes, de las cuales 218 se clasificaron como Vaso sano, 239 como Vaso con placa de calcio, 328 como Vaso con placa fibrotica, y 102 como Vaso con placa mixta (fibrótico, grasa y calcio)³. Esta base de datos sirvió como recurso valioso para el análisis y estudio de las lesiones vasculares de la presente investigación.

5.3. Normalización de Imágenes

Una vez obtenidas las imágenes para cada tipo de lesión en colaboración con expertos en interpretación de ultrasonido intravascular, se emprendió el proceso de normalización. Este proceso consistió en ajustar el tamaño y la resolución de las imágenes utilizando un software de recorte especializado llamado BatchPhoto versión 5.0.1.

La normalización fue crucial para garantizar que todas las imágenes obtuvieran un formato homogéneo, lo que facilitó su análisis y procesamiento posterior, ver Figura 5.3.

El algoritmo de recorte no solo estandarizó el tamaño y la resolución, sino que también ayudó a mejorar la calidad visual de las imágenes, eliminando cualquier variabilidad que pudiera afectar la precisión del análisis. Esta etapa fue fundamental para asegurar que todas las imágenes fueran comparables y coherentes, lo cual es esencial para la eficacia del modelo de análisis automático, ver Figura 5.4.




Figura 5.3: Imagen original.

³<https://doi.org/10.5281/zenodo.14608016>



Figura 5.4: Imagen normalizada.

Una vez que la normalización se completó, la base de datos fue organizada de manera metódica. Las imágenes se agruparon en carpetas separadas, clasificadas según el tipo de lesión, y etiquetadas como M (Mixta), S (Sana), C (Calcificada) y F (Fibrosa). Esta estructura de organización permitió una fácil navegación y acceso a las imágenes, lo que facilitó su uso en etapas posteriores del proyecto.

Con la base de datos completamente preparada y estructurada, se procedió a la implementación del algoritmo de clasificación de imágenes. Este es un paso clave en el desarrollo del modelo de análisis automático de imágenes de ultrasonido intravascular. El algoritmo de clasificación tiene la función de analizar las imágenes y asignarles una categoría específica basada en las características visuales de cada tipo de lesión. Este proceso es fundamental para el desarrollo de un sistema automático capaz de interpretar y clasificar de manera precisa las imágenes de ultrasonido, contribuyendo a una evaluación más eficiente y objetiva de las lesiones vasculares.

5.4. Entorno de Desarrollo

Se creó un programa de cómputo llamado “Proyecto Arterias”, el cual fue programado en lenguaje Python y ejecutado en Jupyter Notebook⁴, y alojado en Google Colab⁵, el cual es un entorno de desarrollo basado en la web que permite escribir y ejecutar código es un entorno flexible.

5.5. Extracción de Características

Las imágenes de ultrasonido intravascular fueron importadas y convertidas a escala de grises para simplificar el análisis. Para cada imagen, se calcularon histogramas de intensidades que representaban la distribución de los niveles de intensidad de los píxeles. Esto es crucial,

⁴<https://jupyter.org/>

⁵<https://colab.research.google.com/>

ya que las imágenes IVUS pueden tener variaciones en la intensidad debido a diferentes condiciones de imagen y características anatómicas, y el histograma proporciona una representación cuantitativa de estas variaciones. Además, resulta necesario realizar una reducción de dimensionalidad para eliminar información irrelevante y, por lo tanto, eliminar tiempos de entrenamiento y optimización del modelo de aprendizaje automático.

5.5.1. Importación y Preprocesamiento de Imágenes

Las imágenes en formato PNG fueron importadas y convertidas a escala de grises. Para asegurar la consistencia en la evaluación, todas las imágenes fueron redimensionadas a 256×256 píxeles, como se describe Sección 5.8.4.

5.5.2. Cálculo del Histograma

Cada imagen se sometió al cálculo de la distribución de la intensidad de sus píxeles en un rango de los 256 niveles posibles, como se describe Sección 5.8.4. ver Figura 5.5

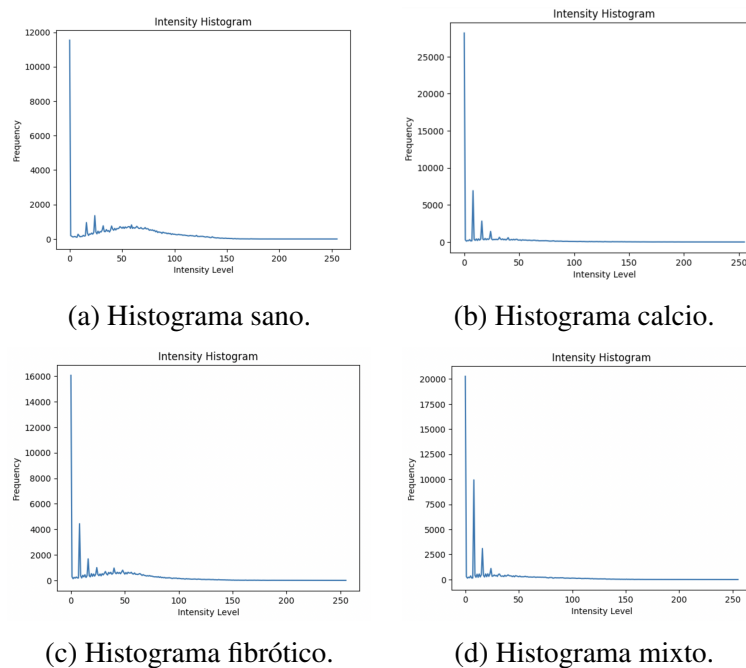


Figura 5.5: Histogramas de intensidad.

5.6. Clasificación

Se entrenaron y evaluaron cuatro clasificadores diferentes para determinar su eficacia en la clasificación de las imágenes de ultrasonido intravascular:

5.6.1. Máquinas de Soporte Vectorial (SVM)

Las Máquinas de Soporte Vectorial (SVM) buscan encontrar un hiperplano que divida de manera óptima las diferentes clases de datos en un espacio multidimensional. Aunque SVM es conocida por su capacidad para manejar datos no lineales mediante el uso de núcleos (kernels), en este caso específico mostró una precisión del 64.6 %. Este resultado indica que, a pesar de su flexibilidad, SVM tuvo dificultades para separar de manera efectiva las distintas clases de imágenes IVUS, lo que sugiere que el modelo podría no haber capturado adecuadamente las características complejas y variadas de las imágenes. Ver Figura 5.6.




Figura 5.6: Matriz de confusión para SVM.

5.6.2. Bosques Aleatorios (Random Forest)

El clasificador de Bosques Aleatorios utiliza un conjunto de árboles de decisión para hacer predicciones. Cada árbol en el bosque contribuye a la clasificación final mediante un proceso de votación. Este método alcanzó una precisión del 79.2 %, demostrando una capacidad notable para manejar la variabilidad y la complejidad inherente a las imágenes IVUS. La precisión relativamente alta sugiere que Random Forest fue eficaz en identificar patrones relevantes y en gestionar la diversidad de características en las imágenes. Ver Figura 5.7

5.6.3. Ingenuo Bayes (Naive Bayes)

El clasificador Naive Bayes se basa en el teorema de Bayes, que asume independencia entre las características para calcular las probabilidades de cada clase. Este clasificador obtuvo una precisión del 65.2 %, lo que lo sitúa por encima de SVM pero por debajo de Random Forest. Aunque Naive Bayes demostró ser más efectivo que SVM, su rendimiento general no alcanzó la efectividad del método de Bosques Aleatorios. Esto puede ser atribuido a la simplificación en las suposiciones del modelo sobre la independencia de las características. Ver Figura 5.8




Figura 5.7: Matriz de confusión para RF.

5.6.4. Vecinos Cercanos (k-NN)

El clasificador vecinos cercanos asigna una clase a cada imagen en función de las clases de sus vecinos más cercanos en el espacio de características. Este método mostró el mejor rendimiento de todos los clasificadores evaluados, alcanzando una precisión del 88.2%. Esta alta precisión refleja la capacidad superior de vecinos cercanos para distinguir entre las diferentes clases de imágenes IVUS, sugiriendo que el enfoque basado en la proximidad a vecinos cercanos fue particularmente efectivo para la clasificación en este contexto. Ver Figura 5.9

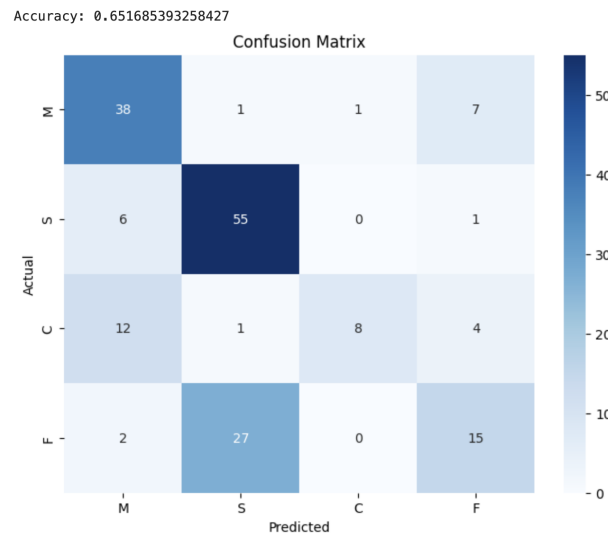


Figura 5.8: Matriz de confusión para Ingenuo Bayes.




Figura 5.9: Matriz de confusión para vecinos cercanos.

5.7. Evaluación

La evaluación de los clasificadores se realizó mediante medidas de precisión (“accuracy”) y matrices de confusión. La precisión indica el porcentaje de clasificaciones correctas, mientras que las matrices de confusión brindan una visión detallada de las predicciones correctas e incorrectas para cada clase.

5.7.1. Precisión y Matriz de Confusión

vecinos cercanos mostró la mayor precisión, seguido por bosques aleatorios, Naive Bayes y SVM. Las matrices de confusión permitieron identificar áreas donde los clasificadores presentaron dificultades y proporcionaron información valiosa para la mejora del sistema de clasificación.

Este enfoque metodológico permite construir una base sólida para el análisis automatizado de imágenes IVUS, mejorando tanto la precisión como la consistencia en la identificación de lesiones arteriales.

5.8. Interface

El desarrollo e implementación de una interfaz funcional para un sistema de clasificación de imágenes de ultrasonido basado en un modelo de aprendizaje automático preentrenado. Este sistema está diseñado para ser ejecutado en el entorno de Google Colab y abarca desde la configuración inicial de bibliotecas y herramientas hasta el proceso completo de clasificación de imágenes.

5.8.1. Importación de Bibliotecas

En primer lugar, es necesario importar las bibliotecas necesarias para la ejecución del código. Estas incluyen herramientas de Google Colab para la manipulación de archivos, OpenCV para el procesamiento de imágenes, y joblib para la carga de modelos preentrenados.

drive

Permite montar el Google Drive en el entorno de Google Colab, proporcionando acceso a los archivos almacenados en él.

files

Se emplea para permitir al usuario subir archivos (imágenes) desde su equipo local al entorno de Colab.

joblib

Se utiliza para cargar modelos de machine learning guardados en formato .pkl.

cv2 (OpenCV)

Es una biblioteca especializada en procesamiento de imágenes y videos, que en este caso se usa para cargar y manipular imágenes de ultrasonido.

numpy

Biblioteca que facilita las operaciones matemáticas y la manipulación de arreglos.

matplotlib

Proporciona funciones para la visualización de gráficos, aunque en este script no se utiliza directamente.

5.8.2. Clonación del Repositorio del Modelo

El código incluye una instrucción para clonar un repositorio de GitHub que contiene el modelo preentrenado y los archivos necesarios para la ejecución del sistema de clasificación. `!git clone https://github.com/eder1234/artery-ultrasound-images-classifier.git` Con este comando, se descarga el repositorio en el entorno de Google Colab, lo cual es esencial para acceder a los modelos y escaladores previamente entrenados.

5.8.3. Carga del Modelo y el Escalador

El siguiente paso consiste en cargar el modelo de machine learning preentrenado y un objeto scaler, el cual se utilizó para normalizar los datos durante la fase de entrenamiento del modelo.

```
model\_filename = '/content/artery-ultrasound-images-classifier/KNN\_m
clf = joblib.load(model\_filename)
scaler\_filename = '/content/artery-ultrasound-images
classifier/svd\_scaler.pkl'
scaler = joblib.load(scaler\_filename)
```

Modelo KNN

El archivo `KNN_model.pkl` contiene el modelo basado en el algoritmo de k-Nearest Neighbors (KNN), que ha sido entrenado previamente para clasificar imágenes de ultrasonido. Este modelo se carga en la variable `clf`.

Scaler

El archivo `svd_scaler.pkl` contiene un objeto scaler que se utilizó para escalar las características de las imágenes durante el entrenamiento. La escalación es necesaria para garantizar que las características de las imágenes de prueba tengan una distribución similar a las del conjunto de entrenamiento.

5.8.4. Preprocesamiento y Cálculo del Histograma de la Imagen

El procesamiento de las imágenes subidas por el usuario comienza con la función `compute_histogram` que convierte cada imagen en su representación de histograma de intensidades de píxeles.

```
def compute_histogram(image_name):
img = cv2.imread(image_name, cv2.IMREAD_GRAYSCALE)
img = cv2.resize(img, (256, 256), interpolation=cv2.INTER_LINEAR)
if img is None:
raise ValueError(f'Failed to load image: {image_name}')
hist = cv2.calcHist([img], [0], None, [256], [0, 256])
return hist
```

cv2.imread(image_name, cv2.IMREAD_GRAYSCALE)

Carga la imagen en escala de grises, ya que este formato es adecuado para el análisis de imágenes médicas, como los ultrasonidos.

cv2.resize(img, (256, 256))

Redimensiona la imagen a un tamaño estándar de 256x256 píxeles para uniformar las dimensiones de entrada al modelo.

cv2.calcHist([img], [0], None, [256], [0, 256])

Calcula el histograma de la imagen, el cual captura la distribución de las intensidades de los píxeles. Este histograma es usado como representación numérica de la imagen para su clasificación.

En caso de que la imagen no pueda cargarse correctamente, se lanza un error con un mensaje descriptivo.

5.8.5. Subida y Clasificación de Imágenes

El sistema solicita al usuario que suba las imágenes de ultrasonido que serán clasificadas. Para ello, se utiliza la función `files.upload()`.

```
uploaded = files.upload()
```

Las imágenes subidas son procesadas en un bucle que realiza las siguientes acciones: carga y cálculo del histograma, escalado del histograma y clasificación utilizando el modelo preentrenado.

```
X = []
for fn in uploaded.keys():
path = '/content/' + fn
histogram = compute_histogram(path)
histogram = scaler.transform(histogram.reshape(1, -1))
X.append(histogram.flatten())
result = clf.predict(np.array(X))
```

`print(result)`

uploaded.keys()

Obtiene una lista de los nombres de los archivos subidos por el usuario.

compute_histogram(path)

Calcula el histograma de la imagen utilizando la función definida previamente.

scaler.transform()

Escala el histograma calculado, ajustándolo al formato del conjunto de entrenamiento del modelo.

clf.predict(np.array(X))

Clasifica la imagen procesada utilizando el modelo de vecinos cercanos cargado previamente. El resultado de la predicción se imprime en pantalla.

CAPÍTULO 6

RESULTADOS

6.1. Métricas de Evaluación

En este trabajo se evaluaron diversos algoritmos de clasificación para abordar un problema de clasificación multiclases. Se buscó identificar las soluciones más efectivas para el conjunto de datos en cuestión, considerando las características específicas del problema planteado. Los modelos fueron comparados en función de métricas de desempeño clave como Exactitud, Puntaje F1, Precisión y Sensibilidad. Estas métricas permiten un análisis detallado del rendimiento de los algoritmos, proporcionando una visión integral de su capacidad para clasificar correctamente las muestras, su balance entre precisión y sensibilidad, así como su efectividad global al enfrentar un escenario de múltiples categorías. El proceso de evaluación incluyó un análisis exhaustivo del comportamiento de los modelos, con el objetivo de identificar cuál de ellos ofrecía un equilibrio óptimo entre dichas métricas, asegurando así una solución robusta y confiable para el problema planteado.

Ver tabla 6.1

Modelo	Exactitud	Puntaje F1	Precisión	Sensibilidad
Máquinas de soporte vectorial (Kernel Poly)	0.6573	0.5818	0.6254	0.6573
Máquinas de soporte vectorial (Kernel RBF)	0.6573	0.6085	0.6281	0.6573
Máquinas de soporte vectorial (Kernel Sigmoid)	0.2921	0.2326	0.1942	0.2921
Bosques aleatorios (Gini)	0.8202	0.8092	0.8409	0.8202
Bosques aleatorios (Entropy)	0.8202	0.8071	0.8364	0.8202
Bosques aleatorios (Log Loss)	0.8202	0.8071	0.8364	0.8202
Ingenuo Bayes	0.6573	0.6322	0.6485	0.6573
Vecinos cercanos (Distance)	0.9157*	0.9161*	0.9180*	0.9157*
Vecinos cercanos (Uniform)	0.8933	0.8923	0.8931	0.8933

Tabla 6.1: Métricas de desempeño de los modelos, con los mejores resultados destacados con un asterisco(*).

- Exactitud (*Accuracy*): Representa el porcentaje de predicciones correctas realizadas por el modelo respecto al total de observaciones. Si bien es una métrica general útil, puede ser engañosa en conjuntos de datos desbalanceados.

- Puntaje F1 (*F1 Score*): Es la media armónica entre la Precision y el Recall, lo que la convierte en una métrica ideal para evaluar el balance entre falsos positivos y falsos negativos. Es especialmente relevante en problemas donde los datos están desbalanceados.
- Precisión (*Precision*): Mide la proporción de predicciones positivas correctas respecto a todas las predicciones positivas realizadas por el modelo. Es fundamental en aplicaciones donde los falsos positivos tienen un costo elevado.
- Sensibilidad (*Recall*): Calcula la proporción de verdaderos positivos detectados frente al total de casos positivos reales. Es clave en escenarios donde la detección de verdaderos positivos es prioritaria.

Estas métricas fueron utilizadas para evaluar diversos clasificadores, incluyendo SVM, Bosques Aleatorios, Ingenuo Bayes y Vecinos cercanos, asegurando un análisis integral del rendimiento de los modelos.

6.2. Resultados por Modelo

6.2.1. Clasificador SVM

SVM con Kernel Polinómico

El kernel polinómico de SVM intenta encontrar una relación compleja entre las características para separar las clases mediante una función de grado elevado. Este método es útil en problemas donde las relaciones lineales entre características no son suficientes para clasificar correctamente. Sin embargo, su rendimiento depende en gran medida del grado del polinomio y de cómo las características estén distribuidas.

En este caso, el modelo obtuvo un Accuracy del 65.73 %, lo que significa que 66 de cada 100 de las muestras de prueba fueron clasificadas correctamente. Este nivel de precisión sugiere que el kernel polinómico fue capaz de capturar algunas relaciones importantes entre las características, pero no todas. La métrica F1 Score, que combina la precisión y el recall, alcanzó un valor del 58.18 %. Esto indica que el modelo tuvo un balance moderado entre las predicciones correctas y los falsos positivos/negativos.

El bajo rendimiento relativo del kernel polinómico podría deberse a que los datos presentan una estructura más compleja que no se puede modelar fácilmente con polinomios. Además, los polinomios de grados altos tienden a sobreajustarse a los datos de entrenamiento, lo que puede llevar a un peor rendimiento en datos de prueba. Por lo tanto, este kernel podría no ser la mejor opción para este problema específico.

SVM con Kernel RBF (Radial Basis Function)

El kernel RBF (por sus siglas en inglés *radial basis function*) es uno de los más utilizados en SVM porque es altamente flexible y puede modelar relaciones no lineales complejas. Este kernel proyecta los datos en un espacio de mayor dimensión utilizando una función gaussiana. De esta forma, busca maximizar la separación entre las clases en este nuevo espacio.

En este análisis, el modelo con kernel RBF logró el mismo Accuracy que el kernel polinómico 65.73 % pero con un F1 Score ligeramente mejorado 60.85 %. Esto indica que el RBF

pudo capturar mejor la relación entre características en comparación con el kernel polinómico. Este modelo puede haber sido menos sensible a las muestras fuera de los patrones generales del conjunto de datos, ayudándolo a evitar errores asociados con la sobrerepresentación de algunas clases.

El kernel RBF suele ser una opción predeterminada en SVM debido a su capacidad para manejar problemas no lineales de manera efectiva.

SVM con Kernel Sigmoide

El kernel sigmoide tiene una estructura similar a una función de activación utilizada en redes neuronales. Se utiliza cuando se espera que las clases puedan separarse mediante relaciones logarítmicas. Sin embargo, este kernel tiene limitaciones significativas, especialmente cuando los datos no tienen una estructura inherentemente sigmoide.

En este caso, el kernel sigmoide fue el peor de todos los clasificadores evaluados, obteniendo un Accuracy de solo 29.21 % y un F1 Score de 23.26 %. Estos resultados indican que el modelo fue incapaz de separar adecuadamente las clases. La precisión extremadamente baja de 19.42 % sugiere que el modelo cometió muchos errores al clasificar las muestras de prueba.

Esto puede deberse a varias razones: el kernel sigmoide puede no haber sido adecuado para la distribución de los datos o los parámetros del modelo no fueron ajustados correctamente. También es posible que las características del conjunto de datos no se ajusten bien a una estructura sigmoide, lo que hace que este kernel sea ineficaz en este contexto.

6.2.2. Clasificador Bosques aleatorios

El algoritmo Random Forest es un clasificador basado en múltiples árboles de decisión que se entrenan en diferentes subconjuntos de los datos. Esto lo hace altamente robusto frente al sobreajuste y permite manejar conjuntos de datos con características complejas. En este análisis, se probaron tres criterios de división: gini, entropy y log_loss.

- **Gini:** Este criterio mide la pureza de las particiones en los árboles. Cuanto menor sea el índice de Gini, mayor será la homogeneidad de las particiones. Con este criterio, el modelo logró un Accuracy del 82.02 % y un F1 Score de 80.92 %. Estos resultados reflejan un balance sólido entre precisión y sensibilidad.
- **Entropy:** Este criterio utiliza la entropía para dividir las características, maximizando la información obtenida en cada partición. Aunque el modelo mostró resultados similares a los obtenidos con Gini, el F1 Score fue ligeramente menor (80.71 %), lo que podría indicar un pequeño ajuste a los datos en esta configuración.
- **Log Loss:** Este criterio, más complejo, optimiza la clasificación minimizando la pérdida logarítmica. Los resultados obtenidos fueron idénticos a los del criterio de entropía, destacando la robustez del modelo.

6.2.3. Clasificador Gaussian Ingenuo Bayes

Naive Bayes es un modelo probabilístico que asume independencia condicional entre las características. Esta simplicidad lo hace rápido de entrenar y fácil de interpretar. En este caso,

Naive Bayes logró un Accuracy de 65.73 % y un F1 Score de 63.22 %. Aunque estos valores son más bajos que los obtenidos por Random Forest o KNN, este clasificador podría ser útil en escenarios donde se requiera una solución rápida y computacionalmente eficiente.

La principal desventaja de Naive Bayes radica en su fuerte suposición de independencia, que rara vez se cumple en problemas del mundo real. Sin embargo, en este caso, logró resultados comparables a los modelos SVM con kernels polinómicos y RBF.

6.2.4. Clasificador Vecinos cercanos

Vecinos cercanos con Pesos por Distancia

Este modelo asigna más peso a los vecinos más cercanos al realizar una predicción. Con esta configuración, vecinos cercanos logró el mejor rendimiento de todos los clasificadores, alcanzando un Accuracy del 91.57 % y un F1 Score de 91.61 %. Esto indica que el modelo fue capaz de capturar correctamente la estructura de los datos y realizar predicciones precisas.

Vecinos cercanos con Pesos Uniformes

En este caso, todos los vecinos tienen el mismo peso, independientemente de su distancia al punto de interés. Aunque esta configuración también mostró un excelente rendimiento, con un Accuracy de 89.33 % y un F1 Score de 89.23 %, fue ligeramente inferior al modelo ponderado por distancia.

6.2.5. Interfaz

Los resultados obtenidos al clasificar imágenes mediante la interfaz desarrollada, la cual implementa el algoritmo de Vecinos Cercanos con ponderación basada en la distancia, reflejan un desempeño altamente confiable. Este modelo fue seleccionado debido a su alta precisión y sensibilidad, alcanzando métricas destacadas como una exactitud de 0.9157, un puntaje F1 de 0.9161, una precisión de 0.9180 y una sensibilidad de 0.9157. Al cargar imágenes de ultrasonido intravascular en la interfaz, el modelo clasifica de manera precisa cada una en una de las cuatro categorías predefinidas, confirmando su eficacia y robustez como herramienta para la clasificación de este tipo de imágenes. Ver Figura 6.1

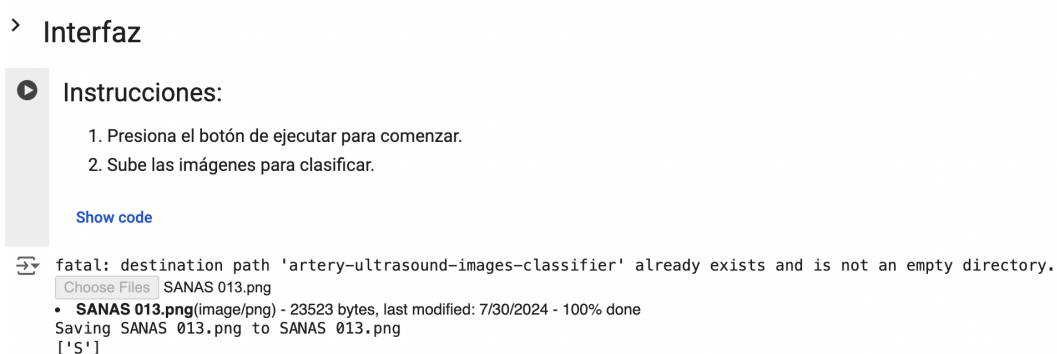


Figura 6.1: Resultados de la interfaz cargada con el algoritmo de vecinos cercanos con pesos por distancias.

CAPÍTULO 7

CONCLUSIONES

La presente investigación concluye que el uso de algoritmos de aprendizaje automático para la clasificación de lesiones intravasculares en imágenes de ultrasonido intravascular constituye una herramienta prometedora para mejorar la precisión diagnóstica, acelerar el proceso de análisis médico y personalizar las intervenciones clínicas. Entre los modelos evaluados, el clasificador Vecinos cercanos se destacó como el más efectivo, alcanzando un 91.57 % de Exactitud y mostrando un balance óptimo entre Precisión y Sensibilidad, gracias a su capacidad para capturar relaciones locales entre las muestras, especialmente al utilizar pesos por distancia. Este modelo sobresale como una solución robusta y eficiente para abordar la complejidad de las imágenes IVUS y facilitar la identificación de diferentes tipos de placas intravasculares.

El modelo Bosques aleatorios se presentó como una alternativa sólida y confiable, con un rendimiento destacable (79.2 % de Exactitud) al emplear el criterio "Gini", lo que lo hace ideal para escenarios donde se prioriza la consistencia y versatilidad. Sin embargo, los modelos Ingenio Bayes (65.2 %) y Máquinas de soporte vectorial (64.6 %) demostraron limitaciones al capturar relaciones complejas entre las características, lo que los posiciona como herramientas más apropiadas para análisis preliminares o situaciones específicas.

Además, el estudio subraya la importancia de las técnicas de preprocesamiento y normalización de imágenes, esenciales para optimizar la representación de los datos y mejorar significativamente el desempeño de los clasificadores. Estas etapas permiten identificar patrones relevantes con mayor precisión y eficiencia, maximizando el potencial de los algoritmos de aprendizaje automático.

Se eligió el modelo de vecinos cercanos como el clasificador final para la interfaz debido a su desempeño superior en todas las métricas clave, demostrando ser la herramienta más robusta y eficiente para la clasificación precisa de imágenes IVUS. Además, su implementación asegura que la interfaz pueda proporcionar resultados confiables y rápidos, optimizando el análisis médico y la personalización de intervenciones clínicas. Este enfoque no solo minimiza el error humano, sino que también mejora la toma de decisiones clínicas al ofrecer una solución objetiva y consistente para la clasificación de lesiones intravasculares.

Referencias

- [1] Lauralee Sherwood. Fisiologia humana: das células aos sistemas. In *Fisiologia humana: das células aos sistemas*, pages 845–845. 2011.
- [2] Kelley Lee. *The World Health Organization (WHO)*. Routledge, 2008.
- [3] Matlab Book. *Mastering machine learning a step-by-step guide with matlab*. 2018.
- [4] Sociedad Española de Cardiología. *Revista española de cardiología. (No Title)*, 1947.
- [5] Mary Cushman, Christina M Shay, Virginia J Howard, Monik C Jiménez, Jennifer Lewey, Jean C McSweeney, L Kristin Newby, Ram Poudel, Harmony R Reynolds, Kathryn M Rexrode, et al. Ten-year differences in women’s awareness related to coronary heart disease: results of the 2019 american heart association national survey: a special report from the american heart association. *Circulation*, 143(7):e239–e248, 2021.
- [6] Paul S Teirstein and Eric J Topol. The role of maintenance of certification programs in governance and professionalism. *Jama*, 313(18):1809–1810, 2015.
- [7] Pierre Sabouret, Michael P Savage, David Fischman, and Francesco Costa. Complexity of antiplatelet therapy in coronary artery disease patients. *American Journal of Cardiovascular Drugs*, 21(1):21–34, 2021.
- [8] David R Holmes Jr, Michael Savage, J-M LaBlanche, Lars Grip, PW Serruys, Peter Fitzgerald, David Fischman, Sheldon Goldberg, Jeffrey A Brinker, AM Zeiher, et al. Results of prevention of restenosis with tranilast and its outcomes (presto) trial. *Circulation*, 106(10):1243–1250, 2002.
- [9] B. K. Koo, A. Erglis, and J. H. Doh. Real-world impact of coronary imaging on clinical outcomes. *Circulation: Cardiovascular Imaging*, 13(5):e010782, 2020.
- [10] R. Hedrich, M. Engelhardt, and M. Gossel. Impact of imaging techniques on coronary intervention outcomes. *Journal of the American College of Cardiology*, 74(8):1020–1032, 2019.
- [11] T. Kovesi, Y. Li, and R. Zhang. Variability in angiographic interpretation: A systematic review. *European Heart Journal*, 42(5):1249–1260, 2021.
- [12] S. Takahashi, T. Kubo, and H. Yamaguchi. Enhancing coronary imaging with intravascular ultrasound. *Cardiovascular Diagnosis and Therapy*, 12(1):58–65, 2022.

- [13] M. Nakamura, H. Kaneko, and K. Ando. Challenges and solutions in intravascular ultrasound imaging. *Journal of Interventional Cardiology*, 34(6):888–897, 2021.
- [14] P. Goel, R. Gupta, and A. Singh. Challenges in coronary angiography: Image quality and interpretation. *Journal of Cardiovascular Imaging*, 12(4):342–356, 2023.
- [15] M. Gonzalez, J. Martinez, and K. Lee. Accuracy of coronary angiography: A review of limitations and implications. *American Heart Journal*, 249:78–89, 2022.
- [16] J. Lee, Y. Chang, and S. Kim. Variability in angiographic interpretation: Implications for clinical decision making. *Circulation*, 143(6):1234–1245, 2021.
- [17] D. Hwang, J. Kim, and Y. Choi. Intravascular ultrasound (ivus) in coronary imaging: Advancements and applications. *European Heart Journal - Digital Health*, 5(1):40–52, 2023.
- [18] J. Miller, R. Wilson, and P. Anderson. Interpreting intravascular ultrasound images: The role of expertise and variability. *Journal of Medical Imaging*, 30(3):143–155, 2022.
- [19] X. Wang, Y. Zhang, and H. Liu. Automated analysis of intravascular ultrasound images using machine learning. *IEEE Transactions on Medical Imaging*, 42(2):365–377, 2023.
- [20] Jan Erik Solem. Programming computer vision with python, 2012.
- [21] Zahra Rezaei. Improved ivus and vh-ivus image segmentation using a hybrid approach based on active counter model and clustering algorithms. *Multimedia Tools and Applications*, pages 1–32, 2024.
- [22] Akiko Maehara, Ecaterina Cristea, Gary S Mintz, Alexandra J Lansky, Ovidiu Dressler, Sinan Biro, Barry Templin, Renu Virmani, Bernard de Bruyne, Patrick W Serruys, et al. Definitions and methodology for the grayscale and radiofrequency intravascular ultrasound and coronary angiographic analyses. *Cardiovascular Imaging*, 5(3 Supplement S):S1–S9, 2012.
- [23] Jinwei Tian, Harold Dauerman, Catalin Toma, Habib Samady, Tomonori Itoh, Shoichi Kuramitsu, Takenori Domei, Haibo Jia, Rocco Vergallo, Tsunenari Soeda, et al. Prevalence and characteristics of tcfa and degree of coronary artery stenosis: an oct, ivus, and angiographic study. *Journal of the American College of Cardiology*, 64(7):672–680, 2014.
- [24] Zhifan Gao, Wei Guo, Xin Liu, Wenhua Huang, Heye Zhang, Ning Tan, William Kongto Hau, Yuan-Ting Zhang, and Huafeng Liu. Automated detection framework of the calcified plaque with acoustic shadowing in ivus images. *PloS one*, 9(11):e109997, 2014.
- [25] Menghua Xia, Wenjun Yan, Yi Huang, Yi Guo, Guohui Zhou, and Yuanyuan Wang. Ivus image segmentation using superpixel-wise fuzzy clustering and level set evolution. *Applied Sciences*, 9(22):4967, 2019.
- [26] Mitsuyasu Terashima, Hideaki Kaneda, Yasuhiro Honda, Tetsuro Shimura, Atsuko Kodama, Maoto Habara, and Takahiko Suzuki. Current status of hybrid intravascular ultrasound and optical coherence tomography catheter for coronary imaging and percutaneous coronary intervention. *Journal of Cardiology*, 77(5):435–443, 2021.

- [27] Daniele Giacoppo, Claudio Laudani, Giovanni Occhipinti, Marco Spagnolo, Antonio Greco, Carla Rochira, Federica Agnello, Davide Landolina, Maria Sara Mauro, Simone Finocchiaro, et al. Coronary angiography, intravascular ultrasound, and optical coherence tomography for guiding of percutaneous coronary intervention: a systematic review and network meta-analysis. *Circulation*, 149(14):1065–1086, 2024.
- [28] John E Hall. *Guyton & Hall. Tratado de fisiología médica*. Elsevier Health Sciences, 2021.
- [29] Frank H Netter. *Netter. Atlas de Anatomía Humana. Abordaje Regional*. 2023.
- [30] Gerard J Tortora and Bryan Derrickson. *Principios de anatomía y fisiología*. Médica Panamericana, 2021.
- [31] Stephan Windecker, Stefan Storck, Giulio G Stefanini, Anne Wilhelmina Rutjes, Marcello Di Nisio, Maria G Siletta, Ausilia Maione, Fernando Alfonso, Peter M Clemmensen, Jean-Philippe Collet, et al. Revascularisation versus medical treatment in patients with stable coronary artery disease: network meta-analysis. *Bmj*, 348, 2014.
- [32] Todd J Anderson, Jean Grégoire, Glen J Pearson, Arden R Barry, Patrick Couture, Martin Dawes, Gordon A Francis, Jacques Genest Jr, Steven Grover, Milan Gupta, et al. 2016 canadian cardiovascular society guidelines for the management of dyslipidemia for the prevention of cardiovascular disease in the adult. *Canadian Journal of Cardiology*, 32(11):1263–1282, 2016.
- [33] Maria Barroso, Albert Goday, Rafel Ramos, Alejandro Marin-Ibanez, Maria Jesús Guembe, Fernando Rigo, Maria José Tormo-Díaz, Conchi Moreno-Iribas, Joan Josep Cabré, Antonio Segura, et al. Interaction between cardiovascular risk factors and body mass index and 10-year incidence of cardiovascular disease, cancer death, and overall mortality. *Preventive medicine*, 107:81–89, 2018.
- [34] George D Dangas, Carlo Di Mario, Holger Thiele, and Peter Barlis. *Interventional cardiology: principles and practice*. John Wiley & Sons, 2022.
- [35] Glenn N Levine, Eric R Bates, James C Blankenship, Steven R Bailey, John A Bittl, Bojan Cercek, Charles E Chambers, Stephen G Ellis, Robert A Guyton, Steven M Hollenberg, et al. 2011 accf/aha/scai guideline for percutaneous coronary intervention: executive summary: a report of the american college of cardiology foundation/american heart association task force on practice guidelines and the society for cardiovascular angiography and interventions. *Catheterization and Cardiovascular Interventions*, 79(3):453–495, 2012.
- [36] H Vernon Anderson, Richard E Shaw, Ralph G Brindis, Kathleen Hewitt, Ronald J Krone, Peter C Block, Charles R McKay, William S Weintraub, and ACC-NCDR*. A contemporary overview of percutaneous coronary interventions: the american college of cardiology–national cardiovascular data registry (acc–ncdr). *Journal of the American College of Cardiology*, 39(7):1096–1103, 2002.
- [37] Gary S Mintz, Steven E Nissen, William D Anderson, Steven R Bailey, Raimund Erbel, Peter J Fitzgerald, Fausto J Pinto, Kenneth Rosenfield, Robert J Siegel, E Murat Tuzcu,

- et al. American college of cardiology clinical expert consensus document on standards for acquisition, measurement and reporting of intravascular ultrasound studies (ivus) a report of the american college of cardiology task force on clinical expert consensus documents developed in collaboration with the european society of cardiology endorsed by the society of cardiac angiography and interventions. *Journal of the American College of Cardiology*, 37(5):1478–1492, 2001.
- [38] Gregg W Stone, Stephen G Ellis, David A Cox, James Hermiller, Charles O’Shaughnessy, James Tift Mann, Mark Turco, Ronald Caputo, Patrick Bergin, Joel Greenberg, et al. A polymer-based, paclitaxel-eluting stent in patients with coronary artery disease. *New England Journal of Medicine*, 350(3):221–231, 2004.
- [39] Sung-Jin Hong, Byeong-Keuk Kim, Dong-Ho Shin, Chung-Mo Nam, Jung-Sun Kim, Young-Guk Ko, Donghoon Choi, Tae-Soo Kang, Woong-Chol Kang, Ae-Young Her, et al. Effect of intravascular ultrasound–guided vs angiography-guided everolimus-eluting stent implantation: the ivus-xpl randomized clinical trial. *Jama*, 314(20):2155–2163, 2015.
- [40] Scot Garg and Patrick W Serruys. Coronary stents: looking forward. *Journal of the American College of Cardiology*, 56(10S):S43–S78, 2010.
- [41] Héctor M García-García, Michael Finizio, David Del Val, Fernando Rivero, Ron Waxman, and Fernando Alfonso. High-definition intravascular ultrasound: current clinical uses. *The International Journal of Cardiovascular Imaging*, 38(6):1213–1220, 2022.
- [42] Mark Lutz. *Learning python: Powerful object-oriented programming*. .°Reilly Media, Inc.", 2013.
- [43] Nello Cristianini. *An introduction to support vector machines and other kernel-based learning methods*. Cambridge University Press, 2000.
- [44] Aurélien Géron. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. .°Reilly Media, Inc.", 2022.