nientos

EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA

TECNOLÓGICO NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

"DESARROLLO DE UN SISTEMA INTELIGENTE DE APOYO A LA DECISIÓN CLÍNICA PARA EL DIAGNÓSTICO DE CÁNCER DE MAMA UTILIZANDO VISIÓN ARTIFICIAL, DEEP Y TRANSFER LEARNING Y EXPLAINABLE AI"

QUE PARA OBTENER EL GRADO DE

MAESTRO EN INGENIERÍA INDUSTRIAL

PRESENTA

I.I. Eduardo Arenas Hernández

DIRECTOR DE TESIS

Dr. Alberto Alfonso Aguilar Lasserre

CODIRECTOR DE TESIS

Dr. Carlos Francisco Vázquez Rodríguez

ORIZABA, VERACRUZ, MÉXICO **MAYO 2026**

Educación
Secretaría de Educación Pública

TECNOLÓGICO NACIONAL DE MÉXICO



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 21/mayo/2026
Dependencia: **División de Estudios de Posgrado e Investigación**
Asunto: **Autorización de Impresión**
OPCION: I

C. ARENAS HERNÁNDEZ EDUARDO
Candidato(a) a Grado de Maestro(a) en:
INGENIERÍA INDUSTRIAL
PRESENTE

De acuerdo con el reglamento de Titulación vigente de los Centros e Institutos Tecnológicos Federales del Tecnológico Nacional de México, de la Secretaría de Educación Pública, y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

DESARROLLO DE UN SISTEMA INTELIGENTE DE APOYO A LA DECISIÓN CLÍNICA PARA EL DIAGNÓSTICO DE CÁNCER DE MAMA UTILIZANDO VISIÓN ARTIFICIAL, DEEP Y TRANSFER LEARNING Y EXPLAINABLE AI

Comunico a usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE
Excelencia en Educación Tecnológica®
CIENCIA - TÉCNICA - CULTURA®

DR. OSCAR BAEZ SENTIES
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

Educación
Secretaría de Educación Pública
INSTITUTO TECNOLÓGICO DE ORIZABA
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OBS/JARH

OG-13-F06



2026
Margarita Maza

100% PLÁSTICO

Orizaba Veracruz, 24/abril/2026
Asunto: Revisión de trabajo escrito

C. OSCAR BAEZ SENTIES
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.:

ARENAS HERNÁNDEZ EDUARDO

La cual lleva el título de:

DESARROLLO DE UN SISTEMA INTELIGENTE DE APOYO A LA DECISIÓN CLÍNICA PARA EL DIAGNÓSTICO DE CÁNCER DE MAMA UTILIZANDO VISIÓN ARTIFICIAL, DEEP Y TRANSFER LEARNING Y EXPLAINABLE AI

y concluyen que se acepta.

A T E N T A M E N T E
Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®

PRESIDENTE:	DR. ALBERTO AGUILAR LASSERRE	FIRMA
SECRETARIO:	DR. CARLOS FRANCISCO VÁZQUEZ RODRÍGUEZ	FIRMA
VOCAL:	DR. RAMIRO MEZA PALACIOS	FIRMA
VOCAL SUP.:	DR. ULISES JUÁREZ MARTÍNEZ	FIRMA

TA-09-118

Agradecimientos

A mis Padres. Por caminar a mi lado desde el principio y ser el pilar fundamental de mi vida. Gracias por creer en mí y enseñarme que todos los sueños se cumplen con dedicación y esfuerzo. - Papá, aunque hoy no estás físicamente presente para poder celebrar este logro, sé que desde el primer momento que te compartí mi deseo de estudiar el posgrado estuviste orgulloso y hoy desde aquí y tomado de la mano de mi mamá podemos gritar hasta el cielo que ¡Lo Logramos! Los amo

A mis Hermanos. Por ser una fuente constante de inspiración para mi vida, con ustedes he crecido y hemos compartido sueños y metas. Gracias por impulsarme a ser mejor y por todo el apoyo que me brindaron desde el inicio. Comparto este logro con ustedes y quiero que sea fuente de inspiración para todo lo que se propongan. Los amo.

Al Dr. Alberto Alfonso Aguilar Lasserre. Quien desde el día que ingresé al posgrado me abrió un panorama enorme sobre todo lo que podría lograr si me lo proponía, por impulsarme a ir más allá de lo evidente y por todas esas charlas y risas que pasábamos en cada asesoría que sin duda alguna formaron una gran amistad, toda mi admiración y respeto. Gracias por creer en mí.

Al Dr. Carlos Francisco Vázquez Rodríguez. Por su invaluable apoyo y gestión para permitir el desarrollo del presente proyecto en el Instituto Mexicano del Seguro Social. Gracias por confiar en mi y otorgarme un poco de su conocimiento que sin duda alguna me enriqueció de manera significativa para la culminación de este trabajo. Lo respeto y admiro Doctor.

A mi familia. A mis tres abuelos por estar presentes y en vida celebrando este logro conmigo, gracias por todas sus bendiciones y palabras de aliento, y a todos los integrantes de mi familia que de una u otra forma aportaron la motivación necesaria para no rendirme. Su alegría y unión fueron importantes para lograr la meta.

A mis profesores de posgrado. Por compartirme su conocimiento con generosidad y pasión. Su guía fue fundamental para obtener este logro. Con una mención especial al Dr. Ramiro Meza quien fue mi profesor desde que estaba en licenciatura y el primero que me platicó como era estudiar un posgrado, fue una gran inspiración durante todo mi proceso académico. Mi respeto para todos profesores.

A mis compañeros de posgrado. Mariana, Ale y Jona, quienes hicieron más ligero este trayecto, gracias por todas las horas, charlas y risas que pasamos juntos, esos desayunos y salidas que sin duda quedarán grabadas en la memoria. A todos los compañeros de MII que en algún momento llegamos a encontrarnos en clases y compartimos conocimiento. Además, a 2 grandes amigos; Fernanda y Enrique quienes dese hace años conozco y hoy están iniciando este camino, les deseo el mejor de los éxitos a todos.

A amigos y personas cercanas. Quienes me brindaron su mano durante este trayecto: Dra. Ita Renaud y Dr. Antonio Fonseca. Gracias por su amistad, visión y compromiso con la salud, ustedes fueron quienes me abrieron el camino y me ayudaron a encontrar este proyecto. A los Investigadores del departamento de epidemiología del HGRO. Dra. Jovanna y Dr. Daniel quienes me brindaron su amistad, apoyo y conocimiento durante mi estancia en el Instituto. A los integrantes de grupo CANIRAC quienes fueron mi primer contacto y me impulsaron a difundir este proyecto en beneficio de las mujeres integrantes de la Cámara y a todos aquellos que de manera indirecta aportaron en este estudio.

Resumen

El cáncer de mama constituye un desafío prioritario de salud pública y una de las principales causas de mortalidad femenina a nivel nacional. La literatura médica establece que el pronóstico de supervivencia depende directamente del diagnóstico temprano mediante tamizaje mastográfico. Sin embargo, áreas operativas clave como el Hospital General Regional de Orizaba (HGRO) No.1 del IMSS de Orizaba, enfrentan serios cuellos de botella debido al alto volumen de estudios. Esta saturación fomenta la fatiga visual en los especialistas, incrementando el riesgo de emitir diagnósticos tardíos o incurrir en falsos negativos durante estadios de desarrollo tumoral encubierto.

Como aportación de ingeniería e inteligencia artificial a esta problemática institucional, la presente investigación de grado expone el diseño, entrenamiento y validación de "Píxel Med AI", un Sistema de Soporte a la Decisión Clínica (CDSS). El objetivo central del proyecto radicó en desarrollar una herramienta predictiva basada en Inteligencia Artificial capaz de analizar topográficamente la agresividad de nódulos y microcalcificaciones mamarias. Su propósito no es sustituir el dictamen del médico radiólogo, sino proveer un escudo de "Segunda Opinión" automática que mitigue la carga sistémica del hospital y reduzca el margen de error humano.

El marco analítico se ejecutó bajo una metodología cuantitativa, multimodal y aplicada. Para conformar la matriz de entrenamiento de la red, se homologaron acervos radiográficos locales en formato DICOM junto con la base académica abierta CBIS-DDSM. La fase de preprocesamiento abarcó la segmentación de Regiones de Interés (ROI) y el Aumento de Datos (*Data Augmentation*) para equilibrar estadísticamente las muestras patológicas. A diferencia del software médico tradicional estructurado con vectores fijos, este modelo se cimenta puramente sobre el espectro del Aprendizaje Profundo (*Deep Learning*).

Para evadir la escasez de datos médicos dictada por las normativas de privacidad, la arquitectura técnica integró la Transferencia de Aprendizaje (*Transfer Learning*). Al importar redes residuales de alto rendimiento, la investigación focalizó el poder de cómputo únicamente en el reajuste fino (*Fine-Tuning*) de las capas de inferencia frente al tejido del seno mamario. Operativamente, el sistema utiliza Redes Neuronales Convolucionales (CNN) amparadas bajo el paradigma dinámico de Aprendizaje Multitarea (*Multi-Task Learning*). Esta estructura permite a Píxel Med AI disgregar asimetrías complejas en la imagen y emitir una clasificación nativa acotada a la normativa probabilística ACR BI-RADS y al Consenso Colima 2025.

Adicionalmente, el proyecto resolvió el riguroso obstáculo bioético del diagnóstico de "Caja Negra", integrando Inteligencia Artificial Explicable (xAI) a través de Mapas de Activación Grad-CAM, el algoritmo transparenta su raciocinio iluminando con mapas de calor las zonas exactas de la mastografía sobre las cuales basó matemáticamente su presunción de malignidad. La evaluación transversal del modelo confirmó una estabilización de aprendizaje lograda gracias a procesos de regularización *Dropout* y restricciones de Parada Temprana (*Early Stopping*). Las métricas arrojaron un poder predictivo sobresaliente, consolidando un 94.6% de Sensibilidad diagnóstica real. Se concluye que Píxel Med AI conforma un ecosistema de triaje altamente confiable, capaz de abatir los tiempos de lectura radiológica y maximizar significativamente la ventana curativa para preservar la vida de las pacientes del sector hospitalario.

Abstract

Breast cancer remains a critical public health challenge and one of the leading causes of female mortality nationwide. Medical literature establishes that survival prognosis relies primarily on early diagnosis through mammography screening. However, key operational areas, such as the Hospital General Regional de Orizaba (HGRO), face significant bottlenecks due to massive study volumes. This saturation fosters visual fatigue among specialists, increasing the risk of delayed diagnosis or yielding fatal false-negative results during early tumor development stages.

As an engineering response to this institutional challenge, this graduate research presents the design, training, and validation of "Píxel Med AI," a Clinical Decision Support System (CDSS). The core objective of the project was to develop a predictive tool based on Artificial Intelligence capable of topographically analyzing the aggressiveness of breast nodules and microcalcifications. Its purpose is not to replace the radiologist's assessment, but to provide an automated "Second Opinion" shield that mitigates visual workload and reduces the margin of human error.

The analytical framework was executed under a quantitative, multimodal, and applied methodology. To shape the network's training matrix, local radiographic repositories in DICOM format were standardized with the open academic database CBIS-DDSM. The preprocessing phase encompassed Region of Interest (ROI) segmentation and Data Augmentation to statistically balance pathology samples. Unlike traditional medical software structured with fixed vectors, this model is purely underpinned by the Deep Learning spectrum.

To circumvent the inherent scarcity of labeled medical data imposed by privacy regulations, the computing architecture integrated Transfer Learning. By importing high-performance residual networks, the research focused its processing capability exclusively on Fine-Tuning the inference layers against breast tissue topologies. Operationally, the system utilizes Convolutional Neural Networks (CNN) underpinned by the Multi-Task Learning dynamic paradigm. This structure enables Píxel Med AI to disintegrate complex asymmetries and native output a probabilistic classification strictly constrained to the international ACR BI-RADS standard and the Consenso Colima 2025.

Additionally, the project resolved the rigorous bioethical obstacle of relying on "Black Box" diagnostics. By integrating Explainable Artificial Intelligence (xAI) through Grad-CAM Activation Maps, the algorithm makes its reasoning entirely transparent, illuminating with heatmaps the exact areas of the mammogram on which it mathematically based its presumption of malignancy.

Abstract

The cross-sectional evaluation of the model confirmed learning stabilization achieved through Dropout regularization and Early Stopping restrictions. The metrics yielded outstanding predictive power, establishing a **94.6% actual diagnostic Sensitivity**. It is concluded that Píxel Med AI constitutes a highly reliable preventative triage ecosystem capable of reducing radiological reading times and significantly maximizing the interventional window to preserve patients' lives within the hospital sector.

INDICE GENERAL

Agradecimientos 4
Resumen 5
Abstract 7
INDICE GENERAL 9
INDICE DE FIGURAS 12
INDICE DE TABLAS 12
INDICE DE ILUSTRACIONES 12
NOMENCLATURA Y GLOSARIO 14
INTRODUCCIÓN 16
Capítulo 1 Generalidades 18
1. Introducción 18
1.1. Planteamiento del problema 19
1.2. Objetivo General 20
1.3. Objetivos particulares 20
1.4. Justificación 21
1.5. Estado del Arte 23
1.5.1 Avances en Detección Basada en Redes Neuronales Convolucionales 23
1.5.2 Hibridación de Frontera y Arquitecturas Expertas 23
1.5.3 El Dominio Escalable del Transfer Learning 24
1.5.4 Deep Learning como sistema de auxilio: Explicabilidad y Multitarea 25
1.6. Tabla de aportaciones 25
1.7. Enfoque Metodológico General del Proyecto. 27
1.7.1. Curaduría Multimodal y Balanceo de Clases Terapéuticas. 27
1.7.2. Implementación Arquitectónica Híbrida y Transferencia Cruzada 27
1.7.3. Tríada de Explicabilidad Clínica (XAI) y Aprendizaje Multitarea 28
1.8. Antecedentes 28
1.8.1. La Era Análoga y la Limitación Biológica 29
1.8.2. Primera Generación de CAD 30
1.8.3. Machine Learning Tradicional y “Feature Learning”. 31
1.8.4. Deep Learning en el Entorno Hospitalario. 31
1.9. Misión 32
1.10. Visión 33
1.11. Valores institucionales 33
1.11.1. Marco Ético 34
1.12. Ubicación 36
1.13. Integración en la Estructura Organizacional Operativa 36
1.14. Procedimiento Institucional de Diagnóstico de Cáncer de Mama en el IMSS 38
1.15. Descripción de los departamentos colaboradores y su rol en el proyecto 40
1.15.1. Departamento de Radiología e imagenología 40
1.15.2. Departamento de Radiología e imagenología 41

INDICE GENERAL

1.16. Taxonomía Tecnológica en la Detección Mamográfica 42
1.16.1. Evolución del Hardware de Adquisición 42
1.16.2. Clasificación de los Sistemas Computacionales de Asistencia (CAD) 43
1.16.3. La Supremacía del Aprendizaje Profundo. 43
1.17. Conclusiones del Capítulo 44
Capítulo 2 Marco teórico 45
2. Introducción 45
2.1. Perspectiva Médica 46
2.1.1. Definición Fisiopatológica del Cáncer de Mama 46
2.1.2. Dimensionalidad Diagnóstica y Estadísticas de Carga Sanitaria 47
2.1.3. Factores de Riesgo Biomédicos del Carcinoma Mamario 47
2.1.4. Taxonomía Histopatológica del Carcinoma Mamario 50
2.1.5. Vías de Propagación y Rutas Metastásicas 51
2.1.6. Modalidades Clínicas de Detección y Diagnóstico 53
2.1.6.1. Mamografía Digital 53
2.1.6.2. Tomosíntesis Digital de Mama (DBT 54
2.1.6.3. Ecografía Mamaria (Ultrasonido) 55
2.1.6.4. Biopsia 56
2.1.6.5. Tomosíntesis Mamográfica 56
2.1.6.6. Tomografía por emisión de Positrones (PET) 57
2.1.6.7. Imágenes Fotoacústicas 57
2.1.6.8. Tomografía computarizada (CT) 58
2.1.7. Sistema BI-RADS: Estandarización y Léxico Radiológico 58
2.1.7.1. Diagnóstico Estructural de la Glándula (Densidades Mamográficas ACR) 59
2.1.7.2. Geometría y Descriptores de Hallazgos (Léxico Visual) 61
2.1.7.3. Geometría y Descriptores de Hallazgos (Léxico Visual) 63
2.1.7.4. Importancia del diagnóstico temprano en el Cáncer de Mama 65
2.1.7.5. Normativa Probabilística ACR BI-RADS y el Consenso Colima 2025 67
2.2. Tecnologías en el diagnóstico de imágenes médicas. 67
2.2.1. Definición y Paradigma de la Inteligencia Artificial Oncológica. 67
2.2.2. Aplicaciones clínicas de la IA Hospitalaria 68
2.2.3. Sistemas de Soporte a la Decisión Clínica (CDSS) 70
2.3. Arquitecturas Algorítmicas para el Filtrado Oncológico Mamario 72
2.3.1. Del Machine Learning Estadístico al Deep Learning Autónomo 72
2.3.2. Redes Neuronales Convolucionales y Mapeo en Estructuras Tisulares. 73
2.3.3. Despliegue Operativo y Sensibilidad Diagnóstica en Cáncer de Mama 74
2.3.4. Transferencia de Arquitectura (Transfer Learning) y Curvas de Maduración Paramétrica Inter-Dominio 75
2.3.4.1. Optimización Fina (*Fine-Tuning*) sobre Redes VGG y ResNet 76
2.3.5. Métricas Paramétricas de Validación y Rendimiento Algorítmico. 76
2.3.6. Obstáculos Bioéticos, Sesgos Topográficos y la Transición a la Explicabilidad (xAI). 77
2.4. Conclusiones del capítulo 2 79
Capítulo 3. Metodología 80
3. Introducción 80
3.1. Enfoque metodológico general 80

INDICE GENERAL

3.1.1. Análisis (Pre-clasificación): 81
3.1.2. Clasificación mediante inteligencia artificial: 81
3.2. Fases de la metodología general del modelo 81
3.2.1. Fase I: Recolección, Fusión y Estandarización de Datos Clínicos y de Imagen. 82
3.2.1.1. Fuente y naturaleza de los datos 82
3.2.2. Fase II: Procesamiento Digital de Imágenes (PDI) y Extracción de Características Radiómicas. 86
3.2.2.1. Preprocesamiento de Imágenes No Estructuradas (Para PDI, Radiómica y CNN) 88
3.2.2.2. Fase III. Modelado y Evaluación de *Machine Learning* Tradicional (MLP y Random Forest) 90
3.2.2.3. Preprocesamiento Digital de Imágenes (PDI) y Extracción de Características Radiómicas 90
- Preprocesamiento Digital de Imágenes 90
3.2.2.4. Extracción de Características Radiómicas 93
3.3. Fase III. Modelado y Evaluación de Machine Learning Tradicional (MLP y Random Forest) 95
3.3.1. Clasificador de Riesgo Clínico (Multilayer Perceptron - MLP) 95
3.3.2. Arquitectura de la Red Neuronal 96
3.3.3. Hiperparámetros 97
3.3.4. El Problema de la "Caja Negra" y la Inteligencia Artificial Explicable 100
3.3.5. Estrategia Mapeo de Activación por Gradientes (Grad-CAM) 100
3.3.6. Estrategia de Evaluación Integral y Métricas de Desempeño 101
3.4. Fase IV. Modelado y Entrenamiento de Deep Learning con Estrategias de Transferencia (Transfer Learning) 102
3.4.1. Gestión Avanzada de Corpus y Preprocesamiento de Tensores 103
3.4.2. Estrategia de Regularización mediante Aumento de Datos (Data Augmentation) 104
3.4.3. Dinámica de entrenamiento y optimización 108
3.4.4. Ajuste Fino (Fine Tuning) 108
3.4.5. Evaluación del modelo de Deep learning y consolidación multimodal 109
3.5. Fase V: Evaluación, Comparación de Modelos y Consolidación Multimodal 110
3.5.1. Protocolo de Comparación de Modelos 110
3.5.2. Análisis de Métricas de Desempeño Clínico 111
3.5.3. Análisis Discriminativo: Curvas ROC Superpuestas 111
3.5.4. Consolidación Multimodal y Selección del Modelo Candidato. 112
3.5.5. Estrategia de evaluación del modelo y métricas de desempeño 114
3.6. Fase VI. Integración del CADx y Validación Clínica Piloto en el HGR de Orizaba 116
3.7. Motor de Dictamen Técnico Automatizado 117
3.8. Conclusiones del Capítulo 118
Capítulo 4. Resultados y Validación del Sistema. 119
4. Introducción. 119
4.1. Dinámica de Entrenamiento y Estabilización de la Red Neuronal 119
4.2. Evaluación Diagnóstica: Protocolo Clínico sobre Casos Inéditos 121
4.3. Matriz de Confusión Aplicada al Tamizaje Oncológico 123
4.3.1. Verdaderos Negativos (TN / True Negatives): 123
4.3.2. Verdaderos Positivos (VP / True Positives) 124
4.3.3. Falsos Positivos (FP / False Positives): 124
4.3.4. Falsos Negativos (FN / False Negatives) 124
4.4. Paradigma Bioético de la Sensibilidad (Recall) frente a la Exactitud Operativa 125
4.5. Demostración de Casos Clínicos y Errores Algorítmicos mediante Grad-CAM 127

4.5.1. Demostración de Casos Clínicos y Errores Algorítmicos mediante Grad-CAM 129
4.6. Materialización Conceptual y Arquitectura Visual del Sistema CADx 132
4.6.1. Interfaz de Usuario Física (UX/UI) y Guía Interactiva de Uso Clínico 133
4.6.2. Guía Interactiva para uso Clínico 138
4.7. Expediente Físico: Resultados del Motor Institucional (Dictamen PDF) 140
4.9. Impacto Logístico y Administrativo para Campañas de Tamizaje masivas 143
4.11. Análisis Comparativo del Estado del Arte 146
4.12. Conclusiones del capítulo 147
Capítulo 5. Conclusiones 148
Bibliografía 151

INDICE DE FIGURAS

Figura 1: Organigrama HGRO, Fuente: Instituto Mexicano del Seguro Social 38
Figura 2: Proceso de Toma de Decisiones para la clasificación de mastografías en el área de Radiología e Imagenología, Fuente: Cantú 2019.. 39
Figura 3: Clasificación de BIRADS Jerarquizada, Fuente: Rostagno 2019 65
Figura 4: Distribución de pacientes por categoría BI-RADS: Goole Colab 83
Figura 5: Flujo de Compensación Estadistica Mediante Inserción Multicéntrica, Fuente: Elaboración Propia 85
Figura 6: Diagrama de Flujo Arquitectura del Modelo CNN, Fuente: Elaboración Propia 97
Figura 7: Arquitectura de la Red Neuronal de aprendizaje multi tarea, Fuente: Elaboración propia 105
Figura 8: Arquitectura de la Red Neuronal Convolucional 107
Figura 9: Fine Tuning, Fuente: Elaboración Propia 109
Figura 10:Arquitectura del Software como dispositivo Médico, Fuente: Elaboración Propia 117
Figura 11: Convergencia de Función de Pérdida 120
Figura 12: Precisión del Modelo (Accuarcy) 120
Figura 13: Métricas globales de rendimiento. Fuente: Elaboración Propia 123
Figura 14: Matriz de Confusión Cínica (Datos de Prueba), Fuente: Datos Propios 124
Figura 15: Distribución de Probabilidad de BIRADS 138

INDICE DE TABLAS

Tabla 1: Aportaciones en el estado del arte 26
Tabla 2: Alineación con el Marco Institucional 34
Tabla 3: Análisis comparativo del estado del arte 146

INDICE DE ILUSTRACIONES

Ilustración 1: Ubicación geográfica del HGRO 36
Ilustración 2: Imagen de Google Maps del HGRO 36
Ilustración 3: Mamografías Digitales 42
Ilustración 4: Tomosíntesis Digital de Mama 43
Ilustración 5: Mamografia Digital, Fuente: Instituto Radiodiagnostico 54
Ilustración 6: Ecografia Mamaria: Fuente: Revista Sintesis 54
Ilustración 7: Resonancia Magnética de Mama, Fuente: Clínica Prevén 55
Ilustración 8: Tomosíntesis Mamográfica, Fuente: MedImagine 56
Ilustración 9:: Tomografía por Emisión de Positrones, Fuente: Elsevier 57
Ilustración 10:: Imágen Fotoacustica de mama, Fuente: MedImagine 57
Ilustración 11: Tomografía Computarizada, Fuente: Carlos V. CESUR 58
Ilustración 12: Secuencia de procesamiento de Mamografía, Fuente: Google Colab 86
Ilustración 13: Preprocesamiento de Imagenes, Fuente: Elaboracion propia 87
Ilustración 14:Segmentación de Mamografía, Fuente: Google Colab 91
Ilustración 15: Selección de Región de Interés, Fuente: CBISDDSM 91
Ilustración 16: Normalización de Intensidad, Fuente: CBIS DDSM 92
Ilustración 17: Filtrado Canny en Imágenes Mamográficas, Fuente: CBISDDSM 92
Ilustración 18: Cadena PDI completa, Fuente: Google Colab 93
Ilustración 19: Extracción de características, Fuente: Google Colab 94

Ilustración 20: Fusión Grad-CAM, Fuente: Elaboración Propia..... 100
Ilustración 21: Transformación del espacio de entrada 104
Ilustración 22: Etorno de programación en Colab 113
Ilustración 23: Fusión Grad-CAM, Fuente: Elaboración Propia..... 128
Ilustración 24: Estudio Verdadero Positivo, Fuente: Pixel Med AI 129
Ilustración 25: Estudio Falso Positivo, Fuente: Pixel Med AI..... 130
Ilustración 26: Estudio Falso Negativo, Fuente: Pixel Med AI..... 131
Ilustración 27: Arquitectura del Sistema Hibrido por Capas, Fuente: Elaboración propia 133
Ilustración 28: Pantalla Principal de Interfaz Gráfica..... 134
Ilustración 29: Barra de entrada de imágenes..... 134
Ilustración 30: Imagen Preprocesada..... 135
Ilustración 31: Dashboard Analítico, Dictamen Clínico y Grad-CAM 136
Ilustración 32: Guía Interactiva de Interfaz Gráfica..... 140
Ilustración 33: Reporte Clínico en PDF..... 142

NOMENCLATURA Y GLOSARIO

- **Inteligencia Artificial de Salud (*Healthcare Artificial Intelligence*):** Rama de la informática dedicada al diseño de algoritmos capaces de emular el raciocinio cognitivo humano para asistir en la prevención, diagnóstico y tratamiento de patologías médicas.
- **Visión Computacional Algorítmica Preventiva de Cáncer de Mama Femenino (*Preventive Algorithmic Computer Vision for Female Breast Cancer*):** Aplicación de técnicas matemáticas y de procesamiento digital de imágenes para identificar de forma anticipada patrones morfológicos o texturas anómalas en mastografías, antes de que el carcinoma sea palpable o clínicamente evidente.
- **Ingeniería Arquitectónica y Modelado de Red Neuronal Profunda y Convolucionales (*Architectural Engineering and Modeling of Deep Convolutional Neural Networks*):** Diseño estructural de sistemas informáticos basados en múltiples capas de neuronas artificiales (filtros convolucionales) que extraen jerárquicamente características visuales complejas desde imágenes médicas en bruto.
- **Algoritmo con Aprendizaje Multitarea Generalizado Matemático Paralelo Integral Integrado (*Integrated Comprehensive Parallel Mathematical Generalized Multi-Task Learning Algorithm*):** Paradigma de entrenamiento algorítmico donde una misma red neuronal resuelve simultáneamente múltiples problemas clínicos interrelacionados (por ejemplo, detectar la presencia de un tumor y clasificar su gravedad al mismo tiempo), compartiendo representaciones matemáticas para mejorar la eficacia y la velocidad del diagnóstico global.
- **Consenso Oncológico Multicéntrico Normativo Nacional Biomédico Interpretativo Internacional Radiográfico Normado ACR y Consenso Colima (BI-RADS) (*National Normative Biomedical Multicenter Oncological Consensus and International Interpretative Radiographic ACR Standard and Colima Consensus*):** Fusión de las directrices globales del Colegio Americano de Radiología (ACR) con la normativa médica hospitalaria nacional de México (Consenso de Colima), garantizando que las decisiones del sistema informático posean estricta validez ética, clínica y legal en el entorno hospitalario local.
- **ACR BI-RADS: Sistema de informe y registro de datos de imagen de la mama (*Breast Imaging Reporting and Data System*).** Es el estándar internacional de oro establecido por el Colegio Americano de Radiología para homologar el léxico mastográfico y clasificar las categorías de riesgo de malignidad.
- **Consenso Colima 2025 Explicabilidad Peritaje Asistencial Diagnóstico de Red Ciega Médica en Visualización Informática Bioética Computacional y Radiológica Demostrable Tangible de Tumor (xAI Grad-CAM) (*Colima Consensus 2025 Explainability, Diagnostic Assistive Expertise of Medical Blind Network in Computational Bioethics and Tangible Demonstrable Radiological Tumor Computer Visualization*):** Aplicación de algoritmos de mapas de activación (Grad-CAM) que transparentan el razonamiento oculto de la red neuronal ("caja negra"). Permite al médico auditar visualmente sobre qué área anatómica de la mastografía basó la IA su dictamen de tumor, cumpliendo con los estándares bioéticos de explicabilidad y confianza médica.
- **Mapeos Híbridos Transferencia Reentrenamiento Local Finamente Afinada Institucional en Plataformas Computacionales Abiertas del Hospital Civil Sector Público (*Hybrid Mappings, Fine-Tuned Institutional Local Retraining Transfer on Open Computational Platforms of the Public Sector Civil Hospital*):** Metodología que consiste en tomar un modelo de inteligencia artificial previamente entrenado con bases de datos globales y someterlo a un reentrenamiento especializado (*Fine-Tuning*) utilizando el acervo clínico y plataformas de código abierto del hospital sede, adaptando así la matemática de la red a las características radiológicas de la población local.

NOMENCLATURA Y GLOSARIO

- **CADx (*Computer-Aided Diagnosis* / Diagnóstico Asistido por Computadora):** Sistemas informáticos que proporcionan una evaluación probabilística de una imagen médica, actuando como una segunda opinión objetiva para ayudar al médico a tomar la decisión final sobre la presencia de patologías.
- **SaMD (*Software as a Medical Device* / Software como Dispositivo Médico):** Clasificación regulatoria otorgada a programas informáticos destinados a fines médicos (como el cribado oncológico) que ejecutan su función sin ser parte del hardware de un dispositivo médico físico.
- **CBIS-DDSM (*Curated Breast Imaging Subset of DDSM*):** Base de datos internacional de acceso abierto financiada por el Instituto Nacional del Cáncer (NCI) de EE. UU., conformada por miles de mastografías escaneadas, estandarizadas y anotadas por expertos, utilizada como "estándar de oro" para entrenar el modelo.
- **DICOM (*Digital Imaging and Communications in Medicine*):** Estándar universal para el manejo, almacenamiento, impresión y transmisión de imágenes médicas. Las mastografías utilizadas por Píxel Med AI ingresan bajo este formato para garantizar la preservación de los metadatos clínicos y la densidad de píxeles sin pérdida.
- **ROI (*Region of Interest* / Región de Interés):** Área gráfica delimitada dentro de una imagen médica (frecuentemente mediante un recuadro o máscara píxel a píxel) que aísla un hallazgo sospechoso, como un tumor o un cúmulo de calcificaciones, para su análisis intensivo algorítmico o humano.

INTRODUCCIÓN

Lejos de ser únicamente una métrica epidemiológica, el cáncer de mama representa hoy en día una crisis global de salud pública y un desgaste estructural para los núcleos familiares. La envergadura del problema es innegable. Para dimensionarlo, basta observar los reportes recientes de la Organización Mundial de la Salud (OMS), los cuales perfilaban hacia 2020 aproximadamente 2.3 millones de diagnósticos novedosos a nivel global; acaparando, en términos prácticos, el 12% de la incidencia oncológica total (World Health Organization [WHO], 2021). A nivel nacional, dicha patología figura de manera alarmante como uno de los principales motores de decesos femeninos. De hecho, estimaciones del Instituto Nacional de Estadística y Geografía (INEGI) apuntan a que este padecimiento concentra cerca del 15% de toda la mortalidad vinculada a tumores malignos en mujeres del país.

Ante este severo panorama, la variable que realmente dicta el pronóstico de una paciente es el tiempo. Adelantarse a la progresión celular resulta crítico. Instrumentos de tamizaje como las mastografías conforman la primera línea de defensa, multiplicando exponencialmente la viabilidad de los tratamientos cuando las lesiones se detectan a tiempo. El obstáculo real suele radicar en la brecha técnica y humana. En diversas regiones del territorio nacional existe una carencia palpable no solo del equipo radiológico necesario, sino de la cantidad suficiente de médicos especialistas capacitados para absorber la alta demanda de lectura de estudios.

Tratando de mitigar estas carencias, la Secretaría de Salud ha operado iniciativas como la Cruzada Nacional contra el Cáncer de Mama (Secretaría de Salud, 2021). Estas políticas de estado se rigen por principios preventivos: desde fomentar la autoexploración periódica hasta establecer el screening mastográfico rutinario a partir de la cuarta década de vida. Sin embargo, generar conciencia social es apenas la mitad del reto; la otra mitad requiere capacidad técnica instalada en los pisos de los hospitales. Es precisamente en esa intersección entre necesidad médica e innovación tecnológica donde surge este proyecto, ejecutado desde las instalaciones del Hospital General Regional No. 1 del IMSS en Orizaba, Veracruz.

Esta sede médica se destaca regionalmente por integrar un mastógrafo digital capaz de generar resoluciones milimétricas. Dicha infraestructura resulta un factor diferenciador, pues la calidad prístina de las capturas es lo que verdaderamente permite una exploración diagnóstica minuciosa, respaldando la vocación pionera del hospital.

Bajo este contexto, la finalidad estructural del proyecto es concebir un Sistema de Apoyo a la Decisión Clínica traccionado por Inteligencia Artificial. Apoyándose en técnicas de Visión Artificial, Deep y Transfer Learning y Explainable AI se buscará asistir la detección del cáncer en sus fases incipientes. La filosofía de desarrollo se basa en el trabajo colaborativo e iterativo con expertos radiólogos del hospital. En lugar de suplantar al especialista, el algoritmo fungirá como una segunda opinión instantánea, mejorando los tiempos de respuesta y dotando a la región de una defensa médica sustancialmente más rápida, certera y eficiente.

Capítulo 1 Generalidades

1. Introducción

El desarrollo de herramientas tecnológicas aplicadas a la salud requiere un marco de referencia claro. Este primer capítulo estructura las bases del presente proyecto de investigación, cuyo fin esencial es la creación de un sistema de apoyo al diagnóstico impulsado por Inteligencia Artificial. La meta es clara: agilizar la detección temprana del cáncer de mama mediante el análisis de imágenes mastográficas. Reducir los tiempos de interpretación radiológica tiene un impacto directo en las tasas de supervivencia de las pacientes, factor que motiva centralmente este esfuerzo.

Para dar contexto, en las siguientes páginas se delinea la arquitectura general del estudio. Partiendo desde una introducción panorámica y el planteamiento puntual del problema, para luego aterrizar en la justificación y los objetivos trazados. Posteriormente, se somete a discusión el estado del arte y se perfila la ruta metodológica que guiará la implementación técnica.

Un trabajo de esta naturaleza demanda, invariablemente, un escenario clínico real para su conceptualización. Por ello, el estudio toma como sede operativa al Hospital General Regional de Orizaba, trabajando en sinergia directa con sus departamentos de Epidemiología e Imagenología. Desde el aspecto técnico, la disponibilidad de un mastógrafo digital en dicha instalación representa un activo de vital importancia, pues garantiza la resolución y calidad de imagen que este tipo de algoritmos exige para operar con precisión. Finalmente, y con el propósito de entender cabalmente el entorno de la investigación, el capítulo cierra detallando la conformación del hospital, enmarcando su misión, visión, valores y el código de ética que rige su día a día.

1.1. Planteamiento del problema

La magnitud de la crisis oncológica mamaria ya ha quedado evidenciada en los registros epidemiológicos; sin embargo, el verdadero nudo crítico del problema no radica únicamente en su alta incidencia, sino en los severos cuellos de botella del proceso diagnóstico. A pesar de que la mastografía se mantiene universalmente como el estándar de oro para el tamizaje, la operatividad en la lectura de estos estudios enfrenta fallas estructurales. Entre las vulnerabilidades más acusadas se encuentra la prevalencia de falsos positivos y negativos. Estos escenarios clínicos son sumamente delicados, ya que derivan en biopsias innecesarias y desgaste psicológico para la paciente, o peor aún, brindan una falsa sensación de seguridad médico-paciente que retrasa fatalmente un abordaje terapéutico.

A nivel de infraestructura humana, interpretar mamografías exige un nivel de especialización y agudeza visual extraordinario. En buena parte de nuestras instalaciones de salud, los médicos radiólogos operan diariamente bajo un volumen de sobredemanda de estudios. Este factor, aunado a la inevitable fatiga visual, abre la puerta a la subjetividad y al error de apreciación en la identificación de microcalcificaciones o masas anómalas.

Aterrizando el panorama, al escenario específico de este proyecto, el Hospital General Regional No.1 del IMSS de Orizaba, en Veracruz, cuenta con la indudable ventaja de poseer un mastógrafo digital. No obstante, el hardware por sí solo no emite diagnósticos. La dependencia total y exclusiva de la experiencia del radiólogo en turno para dictaminar los cientos de estudios solicitados genera una variabilidad preocupante en los diagnósticos. Resulta imperativo, por consiguiente, escalar la capacidad analítica del área de imagenología.

Por el lado del desarrollo de software, la literatura dicta que pretender resolver este cuello de botella contratando infinidad de especialistas muchas veces resulta económicamente insostenible. En contraparte, disciplinas computacionales como el Procesamiento Digital de Imágenes y el Aprendizaje Profundo (*Deep Learning*) han madurado lo suficiente. Estos modelos exhiben una capacidad técnica inaudita para extraer patrones fenotípicos de los tejidos directamente a nivel de píxel patrones que muchas veces escapan al ojo humano no entrenado, pero su implementación operativa en los centros de salud locales sigue siendo mínima.

Por lo tanto, la problemática central que ataca el presente trabajo es la patente ausencia de automatización y respaldo algorítmico en la rutina radiológica de la región. El desafío técnico a resolver consiste en diseñar, entrenar e integrar un modelo de Inteligencia Artificial que filtre o asista de manera ultra rápida el escaneo de mamografías. Cubrir este vacío tecnológico permitiría abatir el riesgo del error diagnóstico por agotamiento humano, blindando el trabajo de los médicos y acelerando la respuesta a mujeres procedentes de una región hospitalaria que suele trabajar a su máxima capacidad con recursos limitados.

1.2. Objetivo General

Desarrollar un Sistema Inteligente de Apoyo a la Decisión Clínica impulsado por Inteligencia Artificial para la detección temprana de anomalías en mamografías, dotando al entorno médico de una herramienta computacional que eleve la precisión escénica, acelere la ventana de respuesta para un diagnóstico oportuno y asegure un tamizaje oncológico más accesible.

.

1.3. Objetivos particulares

Para alcanzar cabalmente la meta global trazada, la ruta ingenieril del proyecto impone dar cumplimiento a los siguientes hitos técnicos y operativos:

- Compilar y estructurar rigurosamente el corpus de imágenes de mamografías (provenientes de bases de datos estandarizadas), aplicando heurísticas de preprocesamiento, aumento de datos (*Data Augmentation*) y normalización de tensores para garantizar el correcto entrenamiento de las redes.
- Diseñar y entrenar una arquitectura de Red Neuronal Convolucional bajo el esquema de Aprendizaje Multitarea, cuya topología permita predecir simultáneamente dos salidas esenciales clínico-patológicas: la clasificación binaria de la masa (Benigno/Maligno) y la estimación de la nomenclatura radiológica acorde al sistema BI-RADS.
- Integrar métodos de explicabilidad algorítmica específicamente el mapeo de activación por gradientes (Grad-CAM) dentro del modelo neuronal, dotando al sistema de la capacidad de generar mapas de calor visuales que le señalen de forma transparente al médico las regiones tisulares que fundamentan su predicción.

- Desplegar el modelo algorítmico en un entorno de usuario gráfico mediante un Sistema de Apoyo a la Decisión Clínica (DSS) llamado Píxel Med AI, el cual procese el estudio radiológico en tiempo real.

- Automatizar un módulo de reporteo clínico dentro del sistema, capaz de generar un documento finalizado (PDF) que incorpore los metadatos del paciente, el veredicto patológico, la estimación BI-RADS y la representación del mapa Grad-CAM como apoyo probatorio.

- Validar y contrastar probabilísticamente el rendimiento del sistema mediante métricas de clasificación, abriendo el canal de colaboración con los especialistas de imagenología del hospital (HGRO) para asegurar que el comportamiento métrico y de reporte de la IA satisfaga los más altos estándares reales de evaluación preclínica.

1.4. Justificación

La batalla clínica y de gestión contra el cáncer de mama representa uno de los mayores desafíos logísticos y financieros para los sistemas de sanidad contemporáneos. Existe un consenso médico irrefutable en torno a este padecimiento: la ventana de supervivencia de la paciente está estrechamente anclada al momento en que se detecta la anomalía. Identificar una lesión en su fase primigenia como pequeñas distorsiones arquitectónicas o microcalcificaciones aisladas permite canalizar a la paciente hacia cirugías conservadoras, multiplicando drásticamente sus posibilidades de recuperación absoluta a largo plazo. Sin embargo, alcanzar este grado de efectividad diagnóstica en el día a día exige un nivel de agudeza analítica que choca de frente con la realidad operativa intrahospitalaria. Aunque la tecnología ha avanzado desde las antiguas placas análogas hasta los mastógrafos totalmente digitales, el dictamen final sigue dependiendo en su inmensa mayoría de la percepción del ojo humano. Esta dependencia estructural genera vulnerabilidades. La exactitud de un reporte radiológico no solo recae en la innegable pericia del especialista, sino que a menudo se ve transgredida por variables logísticas inevitables: la fatiga visual, las constantes interrupciones en el piso clínico y el desgaste cognitivo derivado de despachar largas listas de estudios durante jornadas extenuantes.

Cuando el personal médico debe procesar altos volúmenes de captura bajo presión, las consecuencias del error repercuten en dos vertientes. Por un lado, la omisión inadvertida de una opacidad sutil genera un falso negativo. Este escenario envía a la paciente a casa con una engañosa sensación de salud, dándole tiempo al tejido tumoral para invadir sin síntomas

aparentes. Por el otro extremo, ante la justificada cautela del médico por no "dejar pasar" ningún riesgo, la balanza se inclina hacia la sobredetección. Esto dispara las tasas de falsos positivos, metiendo al sistema de salud en una cadena de biopsias innecesarias que inyectan una pesada ansiedad en la paciente e impactan duramente los presupuestos públicos destinados a confirmaciones histológicas.

Es precisamente para contener estos cuellos de botella en instituciones de alta exigencia, como el Instituto Mexicano del Seguro Social (IMSS) y, en particular, el Hospital General Regional No. 1 de Orizaba, que se justifica el desarrollo de Píxel Med AI.

La integración de arquitecturas de aprendizaje profundo (Redes Neuronales Convolucionales) ofrece un respaldo algorítmico ininterrumpido. Conviene asentar con absoluta claridad que este modelo matemático no busca en ningún escenario reemplazar el talento del radiólogo. Al contrario, este software se erige como un "segundo par de ojos" auxiliar. A diferencia de un profesional médico quien lógicamente sufre desgaste al fijar la vista en un monitor brillante dentro de un cuarto oscuro, el entramado convolucional procesa las matrices de píxeles sin sufrir el mínimo cansancio. El algoritmo aplicará idéntico rigor de atención en la primera mastografía de la tarde que, en la última placa de la madrugada, desterrando de la ecuación la natural curva del error humano.

La materialización de este soporte informático rebasa la mera innovación académica. En regiones como Orizaba, donde el choque entre la tecnología de punta (el mastógrafo) y la limitada cantidad de especialistas genera retrasos ineludibles, automatizar el escaneo preventivo resuelve un problema tangible. Al optimizar los recursos del hospital y abatir tratamientos costosos en fases tardías, la investigación cumple con su fin bioético fundamental: acelerar y afinar la ventana clínica para proteger con certeza la calidad de vida de un mayor número de mujeres.

1.5. Estado del Arte

La incursión metodológica de la Inteligencia Artificial en la imagenología oncológica ha evolucionado significativamente, pasando de ser una teoría especulativa a consolidarse como una herramienta viable en el apoyo al diagnóstico clínico. Las revisiones de la literatura de la última década evidencian la transición operativa desde el análisis estadístico clásico hacia la adopción dominante del *Machine Learning* y, más recientemente, el *Deep Learning*. A continuación, se examinan las investigaciones seminales que estructuran el marco de referencia tecnológico para el presente desarrollo.

1.5.1 Avances en Detección Basada en Redes Neuronales Convolucionales

El posicionamiento de las Redes Neuronales Convolucionales como estándar para la clasificación radiológica no es circunstancial. El estudio ejecutado por (García, 2024) sustenta en gran medida esta adopción, al demostrar la factibilidad de segmentar exclusivamente las Regiones de Interés (ROI) patológico empleando arquitecturas robustas como ResNet y DenseNet. Su investigación comprobó que un modelo profundo adquiere alta precisión para categorizar alteraciones glandulares si se optimiza su entrenamiento únicamente sobre zonas mamográficas depuradas de ruido visual continuo.

En una línea orientada hacia la interoperabilidad clínica, (Akselrod-Ballin, (2016).) sentaron un precedente técnico crucial. El equipo logró entrenar una arquitectura con un corpus de 850 mastografías para identificar características estromales. Su éxito no radicó únicamente en diferenciar masas anormales, sino en lograr que el sistema automatizara sus métricas bajo la escala estandarizada BI-RADS. Este trabajo demostró operativamente que los modelos neuronales poseían la sofisticación requerida para integrarse a normativas de análisis emitidas por comités oncológicos internacionales.

1.5.2 Hibridación de Frontera y Arquitecturas Expertas

A medida que las redes convolucionales maduraban, las líneas de progreso en Inteligencia Artificial comenzaron a buscar la convergencia entre la lectura del píxel y el protocolo ambulatorio. (Cantú, 2019) ejemplifica este salto metodológico al diseñar un sistema capaz de acoplar lógica difusa y extracción vectorial asistida por CNN. Su innovación consistió en

ponderar la historia clínico-patológica de la paciente para ajustar la inferencia final del algoritmo radiológico. Paralelamente, Cantú agrupó este motor computacional en una Interfaz Gráfica de Usuario, priorizando la ergonomía y usabilidad para el operador humano.

Por su parte, (Domínguez, 2022) comprobó la versatilidad espacial de las Redes Profundas al expandir su aplicación hacia reconstrucciones de imágenes fotoacústicas, logrando detectar microestructuras de actividad tumorigénica invisibles a estudios estándar. Finalmente, enfocándose en un rubro microscópico, (Tiezzi, 2020) orientó una topología profunda exclusivamente hacia láminas de histología, con la finalidad de disminuir la variabilidad o sesgo de interpretación cruzada en equipos de patólogos hospitalarios.

1.5.3 El Dominio Escalable del Transfer Learning

Históricamente, uno de los mayores impedimentos para desplegar sistemas de asistencia diagnóstica recaía en la inmensa cantidad de datos exigida para inicializar y balancear una red neuronal desde cero. La solución matemática a este conflicto global se encausó mediante el principio del *Transfer Learning* (Transferencia de Aprendizaje). La experimentación de (André Esteva, 2017) en dermatología oncológica representó un punto de inflexión. Al manipular más de 130,000 registros, demostraron que rescatar y congelar ponderadores (pesos) computacionales de una red pre-entrenada para extrapolarlos a patologías médicas inéditas otorgaba márgenes de acierto comparables a la revisión por especialistas, una métrica de desempeño que eventualmente heredaría la rama mastográfica.

Ejecutando este mismo principio en el análisis morfológico de senos, (Huynh, 2016) condujeron un examen comparativo estricto. Contrastaron el acierto clasificatorio de Máquinas de Soporte Vectorial genéricas frente al procesamiento guiado por una red CNN basada en *transfer learning*. Mediante la evaluación estadística del Área bajo la Curva, la investigación confirmó fehacientemente que la herencia de capas matemáticas preentrenadas catapultaba la calidad predictiva sobre anomalías de mama, otorgándole independencia clínica y viabilidad técnica a los modernos sistemas CADx (Computer-Aided Diagnosis).

1.5.4 Deep Learning como sistema de auxilio: Explicabilidad y Multitarea

A pesar de los formidables e irreversibles aciertos predictivos expuestos previamente, la adopción masiva de arquitecturas convolucionales profundas en el piso clínico se topó históricamente con un muro de contención ético: el dilema de la caja negra. Ante la incapacidad de justificar algorítmicamente y de forma visual el razonamiento detrás de un dictamen positivo a malignidad, la frontera del Estado del Arte se vio forzada a migrar vehementemente hacia el desarrollo de la Inteligencia Artificial Explicable. Como respuesta a esta incisiva demanda médica, técnicas algorítmicas contemporáneas como el mapeo de activación por gradientes propuesto por (Selvaraju, 2017), revolucionaron para siempre la interacción usuario-máquina. Al obligar a la última capa convolucional de la red a generar mapas térmicos superpuestos directamente sobre la mamografía, el modelo abandona el ocultismo informático para iluminar y colorear las coordenadas anatómicas exactas que detonaron su sospecha. Este avance resulta científicamente trascendental, pues transmuta una simple predicción binaria plana en una segunda opinión gráfica, auditable y totalmente rastreable por el radiólogo titular.

En estricto paralelo, buscando mimetizar fielmente la abrumadora complejidad del escrutinio humano oncológico en tiempo real, las experimentaciones más vanguardistas han abandonado las redes de propósito único para transitar hacia el Aprendizaje Multitarea (Caruana, 2017). A diferencia de los modelos fundacionales entrenados para perseguir un solo vector resolutivo (p. ej., sano contra enfermo), el paradigma MTL fuerza a la arquitectura a resolver correlaciones patológicas simultáneas; logrando dictaminar, en una misma fracción de segundo y compartiendo el mismo peso de entrenamiento, tanto la probabilidad de invasión celular como la categorización de escalas clínicas granulares complejas (tales como las subclasificaciones BI-RADS 4a, 4b y 4c). Estas implementaciones de frontera reciente dictan el manifiesto irrevocable de que el futuro de la radiología computarizada no reside meramente en la exactitud matemática invisible, sino en la transparencia diagnóstica interactiva y la evaluación pluridimensional de cada placa.

1.6. Tabla de aportaciones

En la Tabla 1 se muestra una comparación de todos los artículos utilizados para el estado del arte, clasificando cada uno con sus generalidades, técnicas utilizadas y aportación a la investigación.

Nombre del Artículo	Autor(es)	Técnica Utilizada	Aportación a la Ciencia
Detección de cáncer de mama a partir de técnicas de Deep Learning	García (2024)	CNN, Segmentación focal (ROI), ResNet y DenseNet	Demostró empíricamente que aislar el análisis convolucional exclusivamente a las Regiones de Interés (purgando el ruido visual circundante) eleva la precisión predictiva.
Sistema experto para la clasificación de mamografías utilizando Inteligencia Artificial	Cantú (2019)	CNN, Lógica Matemática Difusa y GUI	Validó la viabilidad de cruzar modelos de Deep Learning con cuadros clínicos difusos, encapsulando el algoritmo en una interfaz visual ergonómica amigable para el radiólogo.
Deep Learning aplicado a imágenes fotoacústicas para la identificación de cáncer de seno	Domínguez (2022)	DNN aplicadas sobre ecografía e imágenes Fotoacústicas (PAI)	Comprobó la alta versatilidad de los tensores profundos para procesar fotometría y ambientes 3D, iluminando masa celular invisible bajo modalidades de placa estándar 2D.
Deep Learning como sistema de auxilio, diagnóstico y clasificación de cáncer de mama	Tiezzi (2020)	Procesamiento CNN a nivel de lámina histológica	Suavizó la discordancia de apreciación y el sesgo observacional entre patólogos de planta, automatizando con éxito la estratificación celular directa a escalas de microscopio.
Transfer Learning en la detección del cáncer de piel con redes neuronales profundas	Esteva et al. (2017)	Redes Profundas Masivas bajo *Transfer Learning*	*Hito computacional:* Comprobó que fijar y migrar ponderadores de hiper-arquitecturas ya entrenadas iguala el dictamen oncológico humano, superando definitivamente el freno de la escasez de datos.
Deep Learning para la clasificación histológica de cáncer de mama	Akselrod-Ballin et al. (2016)	Segmentación estromal vía CNN interrelacionada	Definió la metodología de facto para empatar algorítmicamente la extracción de márgenes focales con las categorías ordinales normalizadas del sistema norteamericano clínico BI-RADS.
Comparación de clasificadores de soporte vectorial y CNN para la clasificación de lesiones mamarias	Huynh et al. (2016)	Máquinas de Vector de Soporte (SVM) contrastadas vs CNN	Basado en el registro analítico bidimensional AUC-ROC, comprobó incontrovertiblemente la supremacía técnica del aprendizaje neuronal transferido frente a clasificadores convencionales.

Tabla 1: Aportaciones en el estado del arte

1.7. Enfoque Metodológico General del Proyecto.

El desarrollo experimental se fundamenta en un diseño metodológico de carácter analítico y progresivo. La investigación plantea entrelazar estadísticas clínicas tabulares con módulos de visión computacional basados en *Deep Learning*. Esta arquitectura algorítmica se estructuró a partir de una hoja de ruta dividida en tres fases operativas, cuyo fin último es asistir la evaluación radiológica dentro del entorno oncológico del Hospital General Regional No. 1 del IMSS de Orizaba.

1.7.1. Curaduría Multimodal y Balanceo de Clases Terapéuticas.

El principal obstáculo estadístico de cualquier implementación de IA a nivel local es el sesgo de representatividad que presentan las recopilaciones de datos intrahospitalarias asiladas. Para erradicar este déficit empírico y evitar un indeseable sobreajuste matemático (*overfitting*), la metodología incorpora el Aprendizaje por Transferencia (Transfer Learning) (Pan, 2010)Se homologaron metadatos patológicos y lecturas radiográficas provistas por el HGRO de Orizaba con vectores internacionales del repositorio de código abierto CBIS-DDSM (Curated Breast Imaging Subset of DDSM) (Sawyer-Lee, Cancer Imaging Archive., 2016) . Esta homogeneización garantizó la conformación final de un tensor fotográfico denso, diversificado y con clases terapéuticas óptimamente equilibradas para el ciclo de entrenamiento.

1.7.2. Implementación Arquitectónica Híbrida y Transferencia Cruzada

A modo de métrica comparativa de arranque, el estudio contempló el uso inicial de marcos estadísticos puros como el Perceptrón Multicapa (MLP) y Bosques Aleatorios, orientados a ponderar el peso de las variables del historial clínico del paciente. No obstante, al abordar el denso escrutinio de las mastografías en escala de grises, el diseño recae contundentemente en el uso de Redes Neuronales Convolucionales. Buscando la sensibilidad visual requerida para detectar focos anómalos, el ensamblaje de la red incorporó la directriz de Aprendizaje por Transferencia. A través de esta estrategia, el núcleo algorítmico hereda los pesos o tensores preentrenados de modelos topológicos internacionales (tales como ResNet o VGG16). Este respaldo matemático aceleró drásticamente la capacidad inicial de convergencia de la red, dotando al sistema de la fiabilidad necesaria para discriminar y clasificar bajo los estrictos parámetros del consenso BI-RADS.

1.7.3. Tríada de Explicabilidad Clínica (XAI) y Aprendizaje Multitarea

Rompiendo con el rudimentario formato de las redes de clasificación binaria (que emiten un diagnóstico aislado sin contexto), el modelo profundo de este proyecto se cimienta en el Aprendizaje Multitarea (*Multi-Task Learning)*. Este paradigma arquitectónico obliga a la red a descifrar vectores simultáneos con el mismo esfuerzo computacional: no solo dictamina una alta o baja probabilidad de malignidad, sino que paralelamente categoriza temporalmente el tipo de riesgo y lo alinea con las subclasificaciones institucionales de la norma médica (por ejemplo, categorías métricas de riesgo 4a, 4b y 4c).

Para concluir el flujo y mitigar la natural reticencia médica ante las predicciones tipo "caja negra" generadas en entornos informáticos cerrados, el marco metodológico adopta módulos formales de Inteligencia Artificial Explicable. Mediante la función de mapeo de activación por *Grad-CAM,* la capa final matemática se proyecta visualmente. La red genera de forma superpuesta un rastro topográfico o mapa térmico indicando con extrema precisión espacial en qué regiones estromales basó su dictamen. Esta capa de transparencia rompe el aislamiento del código e instituye una evidencia gráfica auditable a detalle, respaldando íntegramente la evaluación pericial a cargo del médico radiólogo.

1.8. Antecedentes

La línea de tiempo diagnóstica del cáncer de mama y su evolución técnica no pueden entenderse como fenómenos aislados; su avance ha marchado en estricto paralelo. Históricamente, la capacidad clínica para detectar formaciones tisulares incipientes ha dependido directamente de las mejoras mecánicas en los dispositivos de captura y, en la última década, del poder de procesamiento del software de acompañamiento. Revisar este recorrido cronológico resulta de vital importancia para contextualizar un paradigma operativo real: explica cómo instalaciones médicas clave, como el Hospital General Regional de Orizaba (HGRO), han logrado modernizar exitosamente su equipo de hardware radiológico, pero convergen hoy en un severo cuello de botella al tratar de interpretar el volumen masivo de estudios generados. En los apartados subsecuentes se desglosa esta transición histórica, documentando cómo las ciencias médicas han buscado delegar progresivamente la carga del análisis visual hacia el respaldo computacional algorítmico.

1.8.1. La Era Análoga y la Limitación Biológica

Durante gran parte del siglo XX, la mastografía operó ineludiblemente bajo el estándar de la radiología análoga, empleando películas de haluro de plata y negatoscopios iluminados. En esta etapa, el tamizaje oncológico se caracterizaba por ser un ejercicio puramente cualitativo empírico. El acierto en el dictamen recaía por completo en la agudeza óptica y la experiencia visual del médico de turno.

Deede la perspectiva estadística, auditorías clínicas retrospectivas detalladas por (Birdwell, 2021) evidenciaron que el formato análogo poseía graves vacíos de prevención, arrojando tasas rutinarias de omisión y falsos negativos cercanas al 20%. Las limitantes visuales del material físico —tales como el "ruido fotográfico" heredado de los químicos de revelado o la pérdida de luz provocada por el tejido glandular de la paciente— ocultaban fácilmente las microcalcificaciones en etapa inicial. Forzar la vista sobre el acetato iluminado constituía el único método de revisión, conformando un modelo de diagnóstico insostenible ante el constante crecimiento técnico de la demanda poblacional.a Transición Crítica hacia la Mastografía Digital.

El despuntar del siglo XXI catalizó el primer salto cuantitativo drástico mediante la adopción global de la Mastografía Digital (DM) acoplada a la estandarización del protocolo DICOM. Investigaciones fundacionales desplegadas a gran escala demográfica siendo preeminente el histórico estudio multicéntrico DMIST dirigido por (Pisano, 2005) ratificaron y legitimaron de manera incuestionable que la captura digital superaba abrumadoramente a la película análoga.

Esta imperativa curva de digitalización tecnológica logró ser adoptada progresivamente por el IMSS. Específicamente, la asignación y calibración operativa del mastógrafo digital en los gabinetes radiológicos del HGRO solucionó permanentemente el inveterado problema de la captura óptica local: erradicó el ruido análogo y facultó al médico a emplear manipuladores dinámicos de contraste para acechar lesiones milimétricas.

No obstante, esta sublime nitidez adquirida importó simultáneamente un asfixiante efecto colateral: cada paciente tamizada arrojaba en bandeja docenas de reconstrucciones de alta resolución. Ante la carencia sistemática de personal masivo para digerir esta alza, un facultativo en el centro médico invierte hoy un tiempo unitario drásticamente mayor

frente a la pantalla, multiplicando la miopía de desgaste y tensión óptica. El IMSS modernizó con gran esfuerzo *cómo* se captura la imagen, pero retuvo enclaustrado e intacto el pernicioso "cuello de botella interpretativo" puramente humano.

1.8.2. Primera Generación de CAD.

La primera frontera de innovación real llegó a principios del siglo XXI con la adopción masiva de la Mastografía Digital (DM) estructurada bajo el estándar informático DICOM. Investigaciones poblacionales históricas, siendo la piedra angular el estudio DMIST liderado por (Pisano, 2005), lograron ratificar demográficamente que la reconstrucción de imagen a través de matrices de datos superaba definitivamente la limitada visualización de la película análoga.

Como política pública, el IMSS replicó progresivamente esta transición en todo el país. En el panorama regional que nos ocupa, la adquisición y puesta en marcha del mastógrafo digital en pantalla dentro del HGRO solucionó de tajo las carencias del contraste análogo. La captura digital permitió a los facultativos ajustar el brillo y el nivel de los tonos grises de las placas directamente desde la consola, brindando un marco lumínico depurado para ubicar densidades anómalas muy pequeñas.

Pese a este avance técnico irrefutable, el aumento drástico en la resolución de las capturas desató una consecuencia logística a nivel de recursos humanos. Por cada tamizaje digital preventivo, el mastógrafo arroja hoy en día capturas sumamente densas en resolución o proyecciones compuestas que exigen análisis mucho más microscópicos en pantalla. Al carecer de contrataciones extraordinarias de especialistas que absorban esta demanda técnica subyacente, el radiólogo en planta invierte actualmente una cantidad de tiempo notablemente mayor realizando "zoom" e interpretando cada pixel de la placa dictaminada. El IMSS logró erradicar el ruido en la imagen, pero se topó con el segundo muro clínico: mantuvo intacta la sobresaturación cognitiva y biológica del médico, detonando el cuello de botella interpretativo actual.

1.8.3. Machine Learning Tradicional y “Feature Learning”.

Buscando automatizar el cada vez más exigente flujo de revisión visual, la oncoinformática impulsó el uso del Aprendizaje Automático supervisado (Machine Learning clásico), formulando predictores mediante algoritmos como las Máquinas de Soporte Vectorial y los Bosques Aleatorios.

Aunque estas metodologías elevaron la especificidad estadística respecto a los diagnósticos humanos de décadas pasadas, resultaron ser sistemas inviables para escalarse a nivel intrahospitalario debido a una severa restricción de diseño computacional: la extracción manual de características (Feature Engineering). Estos modelos estadísticos carecían de autonomía espacial nativa; requerían forzosamente que un programador o especialista inyectara transcripciones matemáticas (como descriptores de textura de Haralick) para enseñarle al programa cómo buscar el tumor. Si una mastografía capturada en el entorno del IMSS presentaba una atipia microscópica rara o una masa celular que no cuadraba con las fórmulas precargadas, el algoritmo simplemente no la veía. Este sesgo de diseño, también catalogado como una falla iterativa por ceguera metodológica, detuvo temporalmente su consolidación frente a la infinita heterogeneidad anatómica del cáncer.

1.8.4. Deep Learning en el Entorno Hospitalario.

El salto tecnológico definitivo que logra subsanar el rezago informático heredado y que conforma operativamente el pilar y la justificación técnica de la presente tesis computacional llegó con el auge del Aprendizaje Profundo (*Deep Learning*).

La asimilación e implementación matemática de Redes Neuronales Convolucionales (CNN) suprimió por completo la necesidad de "marcarle o describirte" artificialmente al código dónde se esconde el cáncer. Al imitar en cierta medida el desarrollo en capas del córtex visual primario biológico, estas arquitecturas abren la posibilidad técnica de alimentar al sistema con cientos de miles de mastografías crudas. De forma autónoma, el tensor matricial forja y optimiza sus propios filtros matemáticos espaciales para detectar nudos espiculados u ocultos.

Para vislumbrar debidamente la fiabilidad actual de esta tecnología dentro del estado del arte normativo, basta referenciar los rigurosos ensayos internacionales de (McKinney, 2020). Mediante pruebas a doble ciego lideradas empíricamente, McKinney logró documentar probabilísticamente que el algoritmo puramente profundo superaba en rendimiento global al colectivo de radiólogos, al ser capaz de disminuir las tasas de falsos positivos en un 5.7% y reducir los falsos negativos en un 9.4%.

En conclusión, para la dinámica logística del Hospital General Regional de Orizaba, el desarrollo e instauración de un ecosistema CNN local estructurado no representa de ninguna forma un mero esfuerzo teórico o académico de simulación; muy por el contrario, materializa fehacientemente el blindaje necesario para escalar el nivel del servicio del departamento de imagenología. Consolidar el proyecto Píxel Med AI significa entregarle a la región un pabellón radiológico provisto de vanguardia completa: uno metodológicamente capaz tanto de obtener imágenes milimétricas con el entorno visual de la paciente, como de interpretar velozmente y en la misma ventana cronológica una segunda opinión asertiva contra el tiempo de progresión del carcinoma, abatiendo las fragilidades ligadas al agotamiento humano pericial en un sistema de salud demandante.

1.9. Misión

La misión del Instituto Mexicano del Seguro Social (SOCIAL, 2023) es *"Ser la institución de seguridad social con mayor presencia en México, que garantiza el derecho a la salud, la asistencia médica, la protección de los medios de subsistencia y los servicios sociales para el bienestar individual y colectivo de los derechohabientes"*.

En estricta consonancia con este ordenamiento, el presente desarrollo tecnológico funge como un habilitador directo del derecho a la salud. Al dotar al cuerpo médico del Hospital General Regional de Orizaba con una arquitectura de Inteligencia Artificial de aprendizaje profundo, se busca optimizar sustancialmente la logística del análisis radiológico. El sistema asiste al facultativo atenuando la brecha de error provocada por la inherente fatiga visual humana, otorgando mayores posibilidades clínicas para implementar vías quirúrgicas conservadoras e incrementar las tasas de éxito terapéutico en la población.

1.10. Visión

Por su parte, la visión proyectada de la dependencia establece: *"Ser una institución de seguridad social moderna y eficaz, con calidad y calidez en el servicio, liderazgo en el fomento de la salud y la protección social, y de vanguardia en la investigación y desarrollo tecnológico".*

La incursión del análisis de datos vía Deep Learning en el entorno mastográfico converge matemáticamente con el imperativo de mantener la vanguardia investigativa. Adoptar algoritmos clasificatorios avanzados consolida al HGRO como un ente pionero de la medicina asistida por computadora. El sistema asegura una segunda opinión analítica ininterrumpida y homologada a cualquier hora de un turno médico, apuntalando una base operativa tecnológica vital para fortalecer las rutas de detección primaria del cáncer en el estado de Veracruz.

1.11. Valores institucionales

El esquema de valores del IMSS define la rectoría ética del personal. Al automatizar diagnósticos tempranos, el diseño del software y de la base de datos se alineó bajo estos mismos ejes operativos:

- **Honestidad y Transparencia:** En el área de la inteligencia artificial, este concepto se extrapola a través de la explicabilidad de los modelos (*Inteligencia Artificial Explicable o XAI*). El código desarrollado rechaza los métodos impenetrables y otorga transparencia garantizada al generar mapas de calor numéricos. Estos gráficos justifican geográficamente su predicción oncológica, permitiendo al radiólogo auditar visualmente en qué se basa el sistema para dictaminar.

- **Legalidad y Respeto:** Estos fundamentos estructuran la Gobernanza de Datos del proyecto. Como se expone más adelante en el documento, la manipulación del acervo radiológico operó bajo esquemas normativos totales de anonimización de metadatos DICOM; blindando la identidad, confidencialidad y derechos irrenunciables de los registros clínicos procesados a lo largo del estudio.

- **Compromiso y Calidad:** El compromiso tangible de esta red de clasificación neuronal es abatir los umbrales de diagnóstico errado. Sustituir un margen de duda puramente biológica por una estimación matemática rigurosa ayuda a inhibir los sesgos (variabilidad inter e intra observador) y eleva sustancialmente la calidad resolutiva del escenario hospitalario regional.

En la Tabla 2 se resume la alineación estratégica del proyecto con el marco Institucional.:

Principio	Alineación con el Proyecto de IA
Garantía del Derecho a la Salud	Mejora en la accesibilidad y velocidad del diagnóstico.
Vanguardia en Investigación	Desarrollo de tecnología de punta (*Deep Learning*) aplicada a un problema de salud pública.
Calidad de Servicio	Reducción del margen de error diagnóstico (variabilidad interobservador).

Tabla 2: Alineación con el Marco Institucional

1.11.1. Marco Ético.

La aplicación operativa de Inteligencia Artificial dentro de protocolos de evaluación oncológica en pacientes humanos exige la observancia de directrices bioéticas inquebrantables. Para garantizar el bienestar clínico de las usuarias, la presente arquitectura obedece a los siguientes preceptos técnicos:

- **Asistencia Supervisada (*Human-in-the-Loop*):** Todo modelo de predicción carece estructuralmente de autonomía prescriptiva o validez legal aislada. El software aquí desarrollado se clasifica y restringe como un Sistema de Diagnóstico Asistido por Computadora (CADx). Por consiguiente, el fallo definitivo, la validación pericial de hallazgos y el peso de las consideraciones médicas recaerán invariablemente y de forma exclusiva sobre el criterio del radiólogo titular del IMSS.

- **Gobernanza de Datos y Anonimización:** Tanto la extracción de tensores locales como los ciclos de pre-entrenamiento algorítmico operaron bajo las normativas vigentes sobre resguardo de identidad. Todo estudio procesado bajo el estándar DICOM fue disociado íntegramente a nivel de base de datos de los identificadores demográficos civiles (tales como números de seguridad social, CURP o nombres propios), protegiendo fielmente la confidencialidad de la derechohabiente.
- **Principio de No Maleficencia y Equidad Algorítmica:** El objetivo clínico primario de la herramienta preventiva es inhibir cualquier forma de daño físico o psicológico en la paciente. En respuesta a esto, el umbral matemático de pérdida del modelo neuronal fue calibrado para penalizar y suprimir proactivamente los picos estadísticos de falsos positivos. Esta ponderación en el código evita de raíz que una categorización excesivamente sensible desvíe el tratamiento provocando intervenciones quirúrgicas exploratorias, biopsias o extirpaciones perjudiciales e inútiles en mastografías perfectamente sanas.

El compromiso ético se materializa a través de un protocolo técnico para el manejo de los datos con la Pseudonimización de Archivos DICOM: Los archivos de mamografía (DICOM) fueron depurados utilizando *scripts* específicos para eliminar o reemplazar todos los campos que contienen Información de Identificación Personal (IIP), como el nombre, número de seguridad social y fechas exactas. La imagen médica resultante es completamente disociada de la identidad de la paciente.

Los datos anonimizados se alojan y procesan en un ambiente de cómputo seguro, aislado de la red hospitalaria y con acceso restringido exclusivamente al equipo de investigación, lo cual minimiza el riesgo de reidentificación. El desarrollo del modelo de IA, desde la recolección hasta la validación, se lleva a cabo bajo un estricto principio de uso secundario de datos que prioriza la generación de conocimiento y la mejora del sistema de salud sin comprometer la privacidad o la integridad de las pacientes del HGRO.

1.12. Ubicación

El Hospital General Regional de Orizaba está ubicado en Avenida Oriente 6 #2115, Colonia Centro, Orizaba, Veracruz, las ubicaciones se presentan a continuación en la Ilustración 1 y 2.

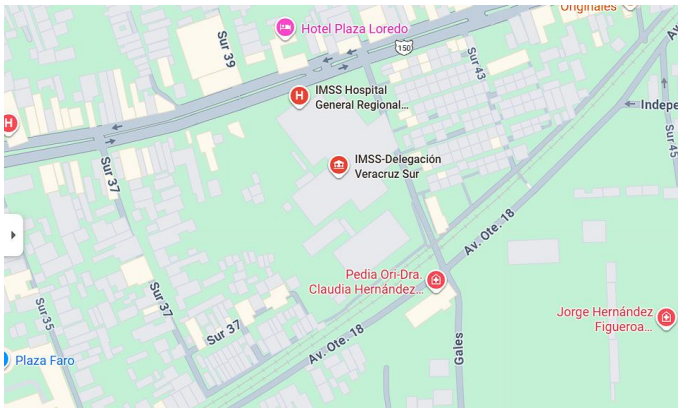


Ilustración 1: Ubicación geográfica del HGRO



Ilustración 2: Imagen de Google Maps del HGRO

1.13. Integración en la Estructura Organizacional Operativa

Como unidad principal en la región, el HGR No. 1 se rige bajo los lineamientos médicos y administrativos inamovibles del IMSS. Esta configuración contempla una jerarquía piramidal y funcional —liderada por direcciones, subdirecciones y líneas de jefatura divisionales— cuyo propósito fundacional es sincronizar los múltiples servicios intrahospitalarios.

En apego a esta logística oficial, la inserción metodológica e informática del sistema Píxel Med AI no pretende sustituir o interferir con la cadena de mando gerencial analógica; su objetivo es incrustarse orgánicamente en el área de apoyo diagnóstico y de investigación experimental del hospital. Llevar el desarrollo computacional del laboratorio informático a la consola médica demandó forzosamente la vinculación de soporte técnico horizontal y simultáneo entre dos ejes clave del edificio:

Jefatura de Servicios de Radiología y Terapia: Como departamento central, funge como el punto de inicio material de la investigación. Es el único agente institucional responsable de generar, resguardar y suministrar las capturas radiológicas base (variables dicotómicas de entrada obligadas para la red neuronal). A la postre, son sus especialistas quienes fungen como certificadores, aplicando de primera fuente la validación analítica sobre los resultados probabilísticos que arroja la inteligencia artificial.

Departamento de Epidemiología y/o Investigación: Ejerce las funciones exclusivas como comité evaluador y agente regulador normativo de la información cruzada. Desde este núcleo directivo se administra el tamaño de la cohorte de estudios, se certifican de oficio los rigurosos filtros de anonimización de expedientes dictados por la ley, y se encauzan los debidos protocolos de validación final.

El éxito logístico y terminal de esta labor recae intrínsecamente en asegurar la armonía funcional. Es decir, que el panel de recomendación gráfica y predictivo operado por el software se ensamble sin generar fricción computacional dentro del ya robusto y saturado flujo de trabajo que rige hoy tanto en pabellones clínicos como de diagnóstico. Esta simbiosis técnica representa uno de los retos organizacionales más complejos del estudio, y por ello obedece formalmente a los lineamientos estructurados dictados a lo largo de la Etapa IV de este paradigma investigativo.

La implementación exitosa del sistema dependerá de la integración fluida de este sistema de apoyo a la decisión en el flujo de trabajo preexistente entre las áreas clínicas y de diagnóstico del HGRO, un desafío que se abordará en la Etapa IV de la metodología.

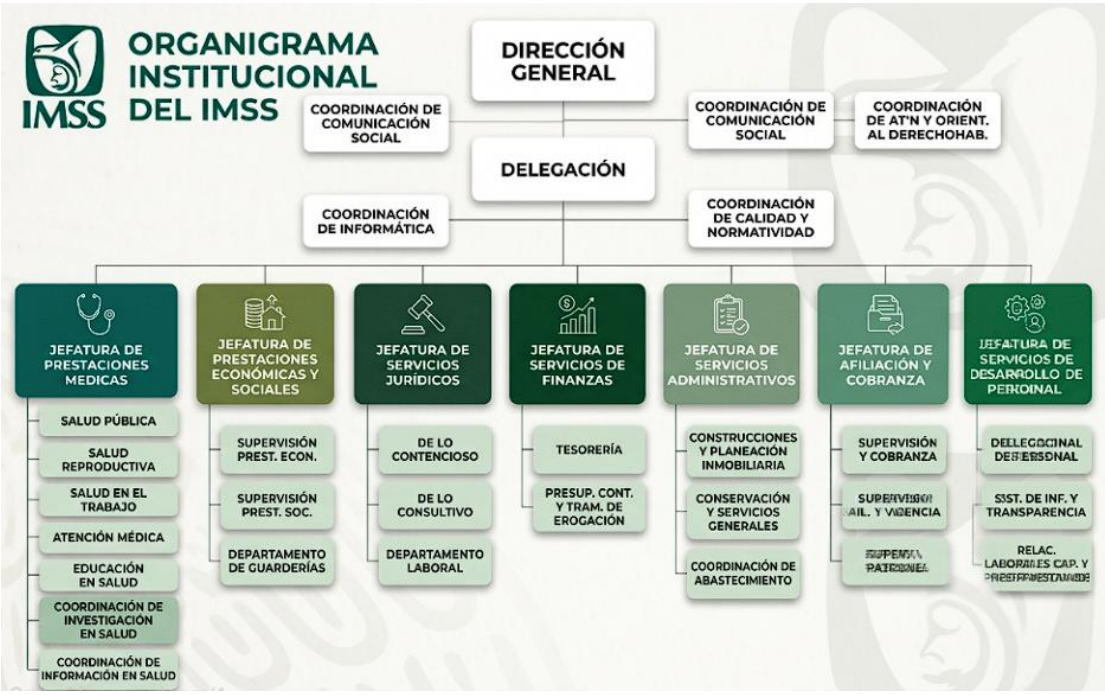


Figura 1: Organigrama HGRO, Fuente: Instituto Mexicano del Seguro Social

1.14. Procedimiento Institucional de Diagnóstico de Cáncer de Mama en el IMSS

Para contextualizar la pertinencia de la herramienta propuesta, es fundamental mapear el proceso clínico y operativo que rige el diagnóstico de cáncer de mama dentro del Instituto Mexicano del Seguro Social (IMSS). Cuando una paciente ingresa al sistema, el flujo de atención comienza con la integración de su Historia Clínica (Herramienta de información), donde se asientan sus antecedentes y factores de riesgo. Posteriormente, se realiza el estudio de mastografía de tamizaje, el cual es canalizado al departamento de radiología.

En esta fase, los especialistas realizan interpretaciones visuales que pueden clasificarse operativamente en una revisión rápida o una revisión lenta detallada, culminando en un dictamen preliminar. Para asegurar el control de calidad institucional, los diagnósticos son sometidos a un proceso de cotejo. Si existe una correlación positiva y un consenso entre las evaluaciones, se determina la gravedad clínica: en casos de bajo riesgo (diagnóstico no grave), la paciente es enviada a un seguimiento de rutina (1 a 2 años); si el diagnóstico es grave, se requiere una evaluación a corto plazo o la canalización inmediata a la especialidad (referencia diagnóstica).

Sin embargo, cuando el cotejo resulta en una discrepancia (ausencia de correlación), el caso es derivado a la Coordinación Auxiliar de Diagnóstico y Tratamiento. Es precisamente en esta

etapa de revisión general —de altísima carga cognitiva para el especialista— donde los sistemas computacionales de apoyo demuestran su valor. Como se detalla en el diagrama de flujo de la Figura 2, el proceso humano de interpretación de imágenes, análisis de características y evaluación de la historia clínica se modela incorporando variables de entrada sistémicas que, mediante técnicas avanzadas (como la unificación de criterios por Lógica Difusa y extracción de características por redes neuronales), permiten emitir un diagnóstico unificado final. Esta modelación del flujo clínico mitiga el error humano, acelera la respuesta institucional y justifica plenamente la integración de Píxel Med AI en la infraestructura actual del IMSS.

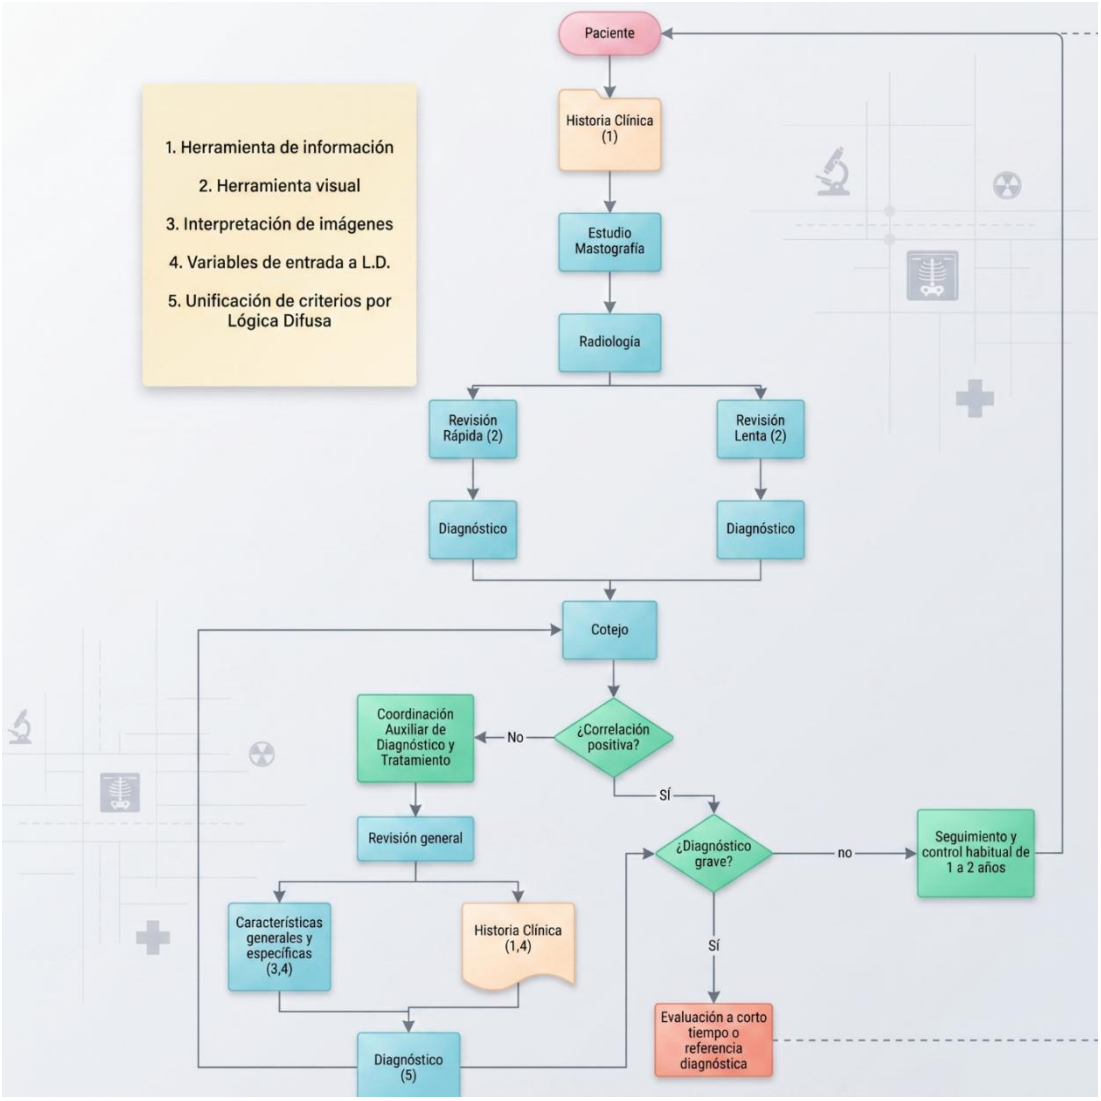


Figura 2: Proceso de Toma de Decisiones para la clasificación de mastografías en el área de Radiología e Imagenología, Fuente: Cantú 2019

.

1.15. Descripción de los departamentos colaboradores y su rol en el proyecto

La viabilidad operativa y el éxito final en la cimentación de un Sistema de Diagnóstico Asistid o (CADx) descansan obligatoriamente en la fusión entre la pericia médica humana y la correct a ingeniería de los datos en cabina. Para nuestro caso de estudio, la investigación consolida su cauce práctico mediante el desarrollo colaborativo e intercomunicado de dos bastiones instituc ionales del HGR No. 1: el Servicio de Radiología y el Departamento de Epidemiología. En la Figura 1 se presenta el Organigrama General Institucional del HGRO.

1.15.1. Departamento de Radiología e imagenología

El área de Imagenología enmarca simultáneamente el inicio y el fin del flujo de trabajo del proyecto. Ejerce como surtidor primario de las capturas visuales y, a la postre, funge como el atril de validación clínica del modelo de Inteligencia Artificial. A nivel informático, la infraestructura de este servicio interconecta el Mastógrafo Digital de Alta Resolución con la red local del Sistema de Archivo y Comunicación de Imágenes (PACS). Este último repositorio conforma la bóveda digital de la cual se recaban metódicamente los archivos en formato DICOM nativo, proveyendo y pavimentando la matriz inicial (dataset) exigida para el entrenamiento de la Red Convolucional.

A nivel de integración humana, el panel de radiólogos especialistas del departamento asume el eslabón crítico inicial: dictaminar la interpretación original del estudio y asentar irrevocablemente la categoría normada del sistema BI-RADS. El dictamen del galeno se transfiere al modelo como métrica de referencia empírica (la conocida "etiqueta analítica" o ground truth), asumiéndola como la pauta indiscutible bajo la cual el ecosistema de Deep Learning computará iterativamente sus índices de error o certeza paramétrica. Para culminar, estos mismos especialistas liderarán analíticamente la Etapa V (Validación Clínica), interactuando de primera mano con la red CADx estructurada para constatar fehacientemente su ergonomía computacional y comprobar de primera fuente su grado de exactitud, la latencia gráfica y el beneficio real que aporta su lectura automática al turno radiológico en pantalla.

1.15.2. Departamento de Radiología e imagenología

Bajo un estricto paraguas normativo ético, el área de Epidemiología o la Unidad de Investigación del hospital salvaguarda la coherencia académica y el manejo prudente de la cohorte matricial seleccionada. Su influencia en el proyecto se segmenta en dos esferas críticas de control:

- **Gestión y Verificación Cruzada de Cohorte:** En su calidad curatorial del historial, Epidemiología avala que el cruce sistémico entre la recolección fotométrica de la mastografía extraída y las actas de resultados a largo plazo (el veredicto de confirmación mediante patología celular o seguimiento anual temporal) sea incuestionable. Aportan una trazabilidad histórica del paciente que valida científicamente si la matriz biológica inicial debe ser matemáticamente catalogada para la Inteligencia Artificial como "malignidad confirmada" o "proceso benigno resuelto".

- **Garantía Normativa y Control de Anonimización:** En sintonía total con los preceptos de la Etapa I, la unidad epidemiológica aplica, asegura y supervisa formalmente la ruta de encriptación para disociar y despojar los bloques que amarran la placa DICOM al nombre o filiación civil de la mujer atendida. Únicamente al depurar el registro sin oportunidad de seguimiento hacia la persona o vulnerabilidad legal, se permite liberar dichos algoritmos hacia la banca de investigación. Del mismo modo, vigilan estadísticamente a la cohorte, impidiendo que desbalances inherentes por demografía de edad o densidades tisulares particulares inserten sesgos ocultos de entrenamiento matemáticamente perjudiciales al futuro modelo algorítmico.

- **Sinopsis del Ciclo Institucional Colaborativo**: A modo de recapitulación operativa lograda, la sinergia investigativa del presente desarrollo describe un bucle funcional perfectamente cerrado dentro de la misma dependencia. El arranque cronológico germina directamente en el hardware de mastografía de Radiología (bóveda PACS). Posteriormente, los bloques migran a Epidemiología para ser rigurosamente cruzados frente a un acta de verdad histórica clínica, aplicando subsecuentemente un vaciado ciego de las variables personales a fin de liberar el *dataset* pulcro y lícito para uso formativo informático. Ya finalizado el entrenamiento, las pruebas y el refinamiento lógico-matemático de la Inteligencia Artificial al lado del equipo desarrollador, la herramienta matriz de Píxel Med AI regresará compilada directamente a la consola de inicio en el área radiológica de origen;

permitiendo con ello cerrar en un proceso circular la modernización y autosuficiencia informática del Hospital General en Orizaba.

1.16. Taxonomía Tecnológica en la Detección Mamográfica

La justificación operativa para consolidar el uso de Inteligencia Artificial en un entorno institucional exige, en primera instancia, comprender las capacidades físicas y analíticas de las herramientas de captura que nutren al proyecto.

1.16.1. Evolución del Hardware de Adquisición

El desarrollo de la mamografía ha pasado por varias etapas durante la historia que han permitido la estandarización del screening o proyecciones en la población, por ejemplo, una Mamografía Analógica (Décadas 1960-1990) caracterizada por el uso de películas radiográficas, esta técnica sentó las bases para la detección temprana. Sin embargo, presentaba limitaciones a la calidad de la imagen (bajo contraste) y la dificultad en el archivo y recuperación de los estudios. A nivel de fotometría o adquisición de datos, el flujo radiológico ha escalado a través de dos estudios tecnológicos formales:

- **Mamografía Digital (Detección por Campo Completo, FFDM**): La introducción de la mamografía digital a finales de la década de 1990 supuso un cambio paradigmático. Al capturar la imagen electrónicamente, se obtuvieron archivos en formato DICOM con una mayor latitud y la capacidad de post procesamiento (manipulación de contraste, brillo, *zoom*). Esta digitalización es la base tecnológica que hace posible la aplicación de sistemas de IA, ya que proporciona los datos de entrada limpios y estandarizados necesarios para el entrenamiento algorítmico. Una mastografía digital se muestra como en la Ilustración 3.

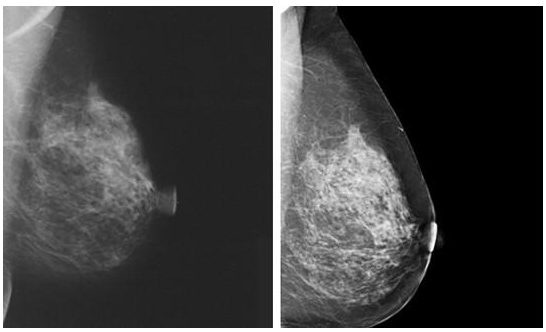


Ilustración 3: Mamografías Digitales

- **Tomosíntesis Digital de Mama (DBT):** Una evolución más reciente que proporciona imágenes en 3D, como se revela en la Ilustración 4, resolviendo problemas de superposición de tejido, aunque es computacionalmente más exigente.

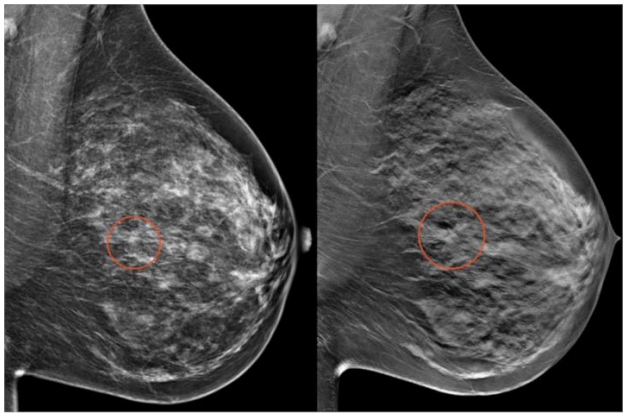


Ilustración 4: Tomosíntesis Digital de Mama

1.16.2. Clasificación de los Sistemas Computacionales de Asistencia (CAD)

En paralelo a la evolución del hardware fotográfico, el área de software persiguió abatir la variabilidad humana del diagnóstico introduciendo los sistemas asistenciales:

Los pioneros Sistemas CAD Tradicionales (basados en *Machine Learning* clásico) irrumpieron en el mercado operando bajo algoritmos estadísticos básicos (tales como SVM o Random Forest). Operaban funcionalmente en dos ramas: a) La Detección Asistida por Computadora (CADe), que se limitaba a sombrear o marcar en pantalla posibles zonas densas para llamar la atención del especialista; y b) El Diagnóstico Asistido (CADx), que trataba de asignar un grado de riesgo a esa misma área. Su defecto paralizante era la dependencia ineludible hacia la Extracción Manual de Características. Si el equipo de ingeniería no programaba manualmente las ecuaciones de textura o forma de un tumor atípico, la máquina nunca lograría abstraerlo o identificarlo estadísticamente en vivo.

1.16.3. La Supremacía del Aprendizaje Profundo.

El muro limitante de la "extracción manual" experimentó su colapso tecnológico entradas las últimas dos décadas, fundamentando la tercera generación del software oncológico: el *Deep Learning*. A diferencia de las familias CAD genéricas, el Aprendizaje Profundo despliega el uso autónomo de Redes Neuronales Convolucionales capacitadas para ejecutar la "Extracción Automática de Características" directamente desde el entramado natural de la imagen cruda. A medida que avanza por iteraciones y capas ocultas, la matriz aprende y refina sus propios filtros

matemáticos internos para reconocer desde texturas y bordes primarios, hasta geometrías malignas complejas. Impulsada por bibliotecas curadas de uso global como CBIS-DDSM, la innovación de frontera ha ratificado que los modelos de aprendizaje multinivel pueden igualar e incluso despuntar sobre la precisión empírica del bloque médico durante ejercicios cruzados de benignidad/malignidad. Abrazar este desarrollo aplicando redes convolucionales y *Transfer Learning* de CBIS-DDSM ancladas a una rigurosa validación operativa interna en instalaciones como el HGRO no se reduce a una simple actualización de interfaz. Representa la evolución pragmática desde una alarma visual pasiva (un CADe rústico) hacia la instauración formal de una segunda opinión Analítica Robusta; dotando al sistema de la autonomía inferencial obligada para emitir con alta fidelidad una dictaminación integral sugerida en categoría BI-RADS.

1.17. Conclusiones del Capítulo

A lo largo de este primer capítulo, se han expuesto las bases fundamentales que justifican la necesidad apremiante de modernizar el flujo diagnóstico oncológico en el Hospital General Regional de Orizaba. Partiendo de la alta incidencia del cáncer de mama y la saturación operativa que enfrentan los especialistas humanos, ha quedado documentado que las herramientas radiológicas actuales, aunque digitalizadas y precisas, no resuelven el cuello de botella interpretativo. El análisis del estado del arte demuestra que las Redes Neuronales Convolucionales (CNN), fortalecidas por técnicas de Inteligencia Artificial Explicable (XAI) y Transfer Learning, superan las limitaciones biológicas humanas y los antiguos sistemas CAD rudimentarios. En conclusión, la implementación de "Píxel Med AI" no busca reemplazar el criterio médico, sino que se alinea con la misión y visión del IMSS al democratizar una atención de alta precisión. Este preámbulo clínico e institucional proporciona el contexto idóneo para profundizar, en el siguiente capítulo, en el Marco Teórico que rige el comportamiento biológico del carcinoma y las bases algorítmicas de la inteligencia artificial empleada.

Capítulo 2 Marco teórico

2. Introducción

Desde una perspectiva de salud demográfica, el carcinoma mamario se instituye de forma constante como una de las patologías oncológicas de mayor amenaza clínica y logística a nivel global. Los modelos estadísticos evidencian que la probabilidad endógena de que una paciente desarrolle esta proliferación celular anómala a lo largo de su ciclo biológico vital ronda el 12.5% (el equivalente a un diagnóstico positivo por cada ocho mujeres). Esta altísima tasa de incidencia consagra al padecimiento como una emergencia de carácter público ineludible.

La prevalencia de supervivencia frente a este escenario no depende unívocamente de la agresividad en los tratamientos de contención, sino de explotar al máximo la ventana preventiva. Interceptar la anomalía en sus estadios morfológicos iniciales altera positivamente y de raíz el pronóstico de recuperación. En la búsqueda por dominar este margen de detección, la medicina se ha soportado por décadas en recursos mecánicos como la placa mastográfica o enfoques magnéticos invasivos. Sin embargo, la irrupción informática reciente ha consolidado rutas inexploradas para la clínica hospitalaria: el *Deep Learning* y las matrices de Inteligencia Artificial exhiben hoy la robustez necesaria para auditar con extremada agudeza dichas capturas, abatiendo las deficiencias humanas en el tamizaje preventivo.

Consecuentemente, el presente capítulo estructura los cimientos teóricos y conceptuales que amparan el desarrollo de este proyecto. En los bloques venideros se desarrolla una exploración dual pormenorizada. En una primera instancia, se desglosan los pilares biomédicos del fenómeno: fisiología de la neoplasia, sus causales epidemiológicas y el protocolo de diagnóstico conservador vigente (imagenología y confirmación por biopsia celular). Posteriormente, dicha normativa hospitalaria se amalgama técnica y directamente con la base de las ciencias de cómputo; elucidando con exactitud conceptual cómo las familias de Redes Neuronales Convolucionales logran deconstruir la imagen fotográfica del seno para decodificar patologías y erigirse como un filtro radiológico automatizado de segunda opinión.

2.1. Perspectiva Médica

2.1.1. Definición Fisiopatológica del Cáncer de Mama

En términos de patología celular microscópica, el cáncer no se define primariamente como una enfermedad aislada, sino como un conjunto sistémico de alteraciones detonadas por la pérdida estructural de la homeostasis biológica de los tejidos. Mientras que una unidad celular sana obedece estrictamente a ciclos de reproducción finitos y a secuencias de muerte celular programada (apoptosis), la variante celular cancerígena padece de mutaciones en sus candados bioquímicos, provocando una proliferación caótica y acelerada de masa pura. En la nomenclatura clínica oficial, la denominación general de "cáncer" se aplica y restringe exclusivamente a aquellos conglomerados tisulares (neoplasias malignas) que ostentan un carácter invasivo contundente; es decir, que poseen la perniciosa capacidad biológica de perforar las barreras de tejido adyacente y diseminarse hacia otras topografías del cuerpo humano a través de mecanismos como la metástasis. En franca contraparte, el dictamen patológico de "tumor benigno" se reserva para aquellas masas silentes limitadas y asintomáticas, las cuales carecen orgánicamente de poder infiltrativo.

Estrechando este marco biológico al enfoque del presente desarrollo, el caso particular del carcinoma de mama agrupa sistemáticamente y desde el punto de vista ginecológico a todas aquellas ramificaciones malignas originadas internamente en la glándula del seno. Su diagnóstico tipológico obedece al foco primigenio (etiológico) de la mutación: si la célula neoplásica se conforma en los canales intratisulares que facilitan el acarreo de leche hacia el pezón, el bloque se clasifica como una modalidad de *carcinoma ductal*; subsiguientemente, si la deformación física emana directamente en los alvéolos encargados de la propia segregación, recae en la subvariante de *carcinoma lobulillar*. Con referencia a su grado de letalidad u horizonte temporal de abordaje quirúrgico, la patología oscila entre un estatus *in situ* (formación atrapada herméticamente en su cuadrante orgánico original) y un rango invasivo (donde la masa rompió contención biológica y emprendió una ruta de colonización sistémica).

2.1.2. Dimensionalidad Diagnóstica y Estadísticas de Carga Sanitaria

El desgaste logístico y de morbilidad que arrastra consigo esta malformación mamaria exhibe una estadística preocupante para cualquier estado u órgano de salud en el escenario mundial. Cifras históricas auditadas de forma ininterrumpida por la Organización Mundial de la Salud respaldan holgadamente la gravedad: tan solo en cortes analíticos recientes, este padecimiento monopolizó en términos prácticos una cuarte parte absolutista (el 25%) del volumen demográfico total de cáncer diagnosticado a mujeres globalmente (World Health Organization [WHO], 2021). Su impacto severo no obedece a límites geográficos o de renta demográfica; en Norteamérica, los consolidados normativos emitidos por la instancia oncológica (American Cancer Society (Sociedad Americana contra el Cáncer), 2017) posicionan a esta variable celular como el desencadenante de al menos una de cada tres defunciones prevenibles y vinculadas a entidades tumorales en pacientes de la región.

Aterrizando esta severidad de forma contigua hacia nuestras latitudes locales, la radiografía expone vulnerabilidades operativas simétricas para el territorio nacional y su Sistema de Salud gubernamental adyacente. Los registros epidemiológicos y de censo emitidos por la propia Secretaría de Salud de México (2020) dictaminan categóricamente que este espectro neoplásico acapara hoy en día el 30% ineludible de cualquier diagnóstico por tumoración maligna procesado a pacientes femeninas. Traducido a mortalidad, este flujo engendra una desmoralizadora tasa documentada de 6.8 decesos directos por cada cuña estandarizada poblacional de 100,000 mujeres locales. Este panorama lúgubre legitima —de forma indudable— cualquier avance algorítmico hospitalario, cimentando de facto las bases, la extrema necesidad técnica y la urgencia ética de implementar arquitecturas de soporte inteligente y detección rápida como el motor principal expuesto en este documento.

2.1.3. Factores de Riesgo Biomédicos del Carcinoma Mamario

Alineándose con los parámetros epidemiológicos expuestos por iniciativas intergubernamentales como la *Global Breast Cancer Initiative* de la OMS, se reconoce ampliamente en el sector clínico que la aparición del carcinoma mamario responde, sin dudar, a un fenómeno de etiología multifactorial. Una red extensa de catalizadores biológicos y externos inciden directamente tanto en la génesis celular como en la progresividad final del tumor. Para el escenario nosocomial en México, deconstruir y perfilar esta amalgama de

desencadenantes resulta estratégico, pues de la comprensión de estas características nacerán los parámetros preventivos adecuados al estrato cultural. Analítica y patológicamente, estos factores de incidencia convergen en dos vías operativas diametrales: los extrínsecos (modificables por hábitos) y los factores intrínsecos de base (inmodificables).

2.1.3.1. **Variables Intrínsecas (Atributos Inmodificables)**: Esta categorización acapara el peso del riesgo anclado indisolublemente a la demografía, el desarrollo biológico y la herbolaria o mapa genético de la paciente:

- **Envejecimiento Celular Continuo:** La madurez etaria funge históricamente como el vector biológico del mayor peso patológico. Retrospectivamente, la morbilidad de la enfermedad se dispara y concentra a partir de la quinta década de vida; rango en el que recaen estadísticamente cerca del 80% de los diagnósticos oncológicos validados.

- **Carga Genética y Antecedente Hereditario:** La alteración confirmada de tensores o genes supresores específicos —subrayando las ramificaciones BRCA1 y BRCA2— explica desde adentro aproximadamente entre un 5% y 10% del origen casuístico del cáncer de mama, tal como ha respaldado la literatura fundacional documentada por (Y. Miki, 1994). Si este entorno mutado recae además sobre el antecedente directo de malformaciones en consanguíneos de línea primera y temprana edad, la ventana general de la vulnerabilidad se infla agudamente.

- **Sujeción Fisiológica de Sexo:** Acotando a un marco elemental biológico, ser mujer dota naturalmente al tejido mamario del cuerpo de las variables estructurales y las cascadas hormonales perfectas requeridas para soportar estas divisiones celulares atípicas constantes.

2.1.3.2. **Variables Ambientales y Endócrinas (Modificables)**: Este clúster de estudio engloba agentes fisiológicos o toxicologías fuertemente vinculadas a las resoluciones del estilo de vida diario y a perfiles ginecológicos transitorios:

- **Afecciones Endócrinas por Obesidad:** Con especial virulencia tras culminar la ventana postmenopáusica, los altos índices grasos de adiposidad en la paciente se correlacionan directamente con un riesgo tumorigénico superior. Biológicamente,

esto se suscita debido a que el estrato grueso de tejido adiposo abandona su supuesta pasividad y se convierte en un emisor o productor biológico que inyecta elevadísimos niveles de estrógenos activos al torrente de la mujer (Wu, 2013).

- **Sedentarismo Crónico y Toxicidad Orgánica:** El estancamiento de la actividad o metabolismo muscular resultante del sedentarismo frena fuertemente la nivelación o regulación hormonal del cuerpo (Wu, 2013). Acoplado a esto, un consumo constante y desmedido de compuestos procesados (alcohol o destilados) daña a celularidad general e inyecta patentes probabilidades incrementales hacia un desarrollo anormal de tejido.

- **Madurez Reproductiva y de Gestación:** Un vector clave e intrigante radica en el comportamiento endocrino arrastrado a lo largo de la edad fecunda de la paciente. Las proyecciones clínicas afirman que la total nuliparidad (nunca llevar a cabo un parto) o diferir radicalmente el desarrollo y parto del primer producto superadas las tres décadas de vida, agrega leves factores de tensión de riesgo a la salud mamaria. Por el polo contrario, gestar tempranamente exhibe y arroja matemáticamente un ligero "aislante" natural y protector para el busto. (Es oportuno hacer la cautela: este patrón protector gestacional es sumamente frágil e inestable frente a ciertas variantes patológicas crueles, como ejemplo de choque que en ramificaciones salvajes como lo es el cáncer "Triple Negativo", un transcurso del embarazo de forma aislada puede llegar a detonar o elevar paradójicamente el peligro inmediato).

- **Exposición y Sobresaturación Farmacológico-Hormonal:** Apelar a metodologías preventivas como comprimidos recetados o inyecciones de base anticonceptiva altera el curso orgánico hormonal de los niveles de choque fisiológicos. Pese a reportar un alza transitoria interina en materia endócrina durante la dependencia cíclica de esas recetas orales preventivas dictaminadas ginecológicamente, los estudios a muy larga distancia garantizan afortunadamente que tal factor amenaza sufre un decremento y retorno lineal base al cruzar el límite de la década libre tras suspender voluntariamente la ingesta.

2.1.4. Taxonomía Histopatológica del Carcinoma Mamario

La manifestación celular de esta patología clínica demanda institucionalmente una segmentación y evaluación rigurosa basada en dos ejes biológicos cruzados: el epicentro orgánico exacto de su origen (si brota en los canales deductores o en los lóbulos de secreción) y el radio de penetración microscópica o invasión que ejerce sobre el entorno que le rodea (American Cancer Society, 2023).

Desde la perspectiva de la imagenología computarizada, para la correcta parametrización y aislamiento visual que exige ejecutar un algoritmo como una Red Convolucional (CNN), la diferenciación médica de estas variantes resulta crítica, puesto que cada una de ellas le arroja a la lente biológica del mastógrafo una "firma focal" radiográfica distinta. El estándar oncológico las estratifica en las siguientes etapas (World Health Organization [WHO], 2021):

- **Carcinoma Ductal *In Situ* (CDIS):** Representa en estricto rigor patológico una neoplasia de etapa inicial o "cero" con nula actividad invasiva. Arquitectónicamente, la deformación de las células se gesta, se replica y languidece atrapada por completo en el aislamiento geográfico endógeno de los ductos lactíferos. Al no certificar una fractura destructiva de las paredes de la membrana periglandular (que implicaría brincar al tejido mamario contiguo), ostenta un brillante panorama quirúrgico de cura. En lectura asistida, el CDIS frecuentemente engaña al ojo dictaminador proyectándose como aglomeraciones de tenues nubes salpicadas conformando microcalcificaciones inertes (American College of Radiology. , 2019).

- **Carcinoma Lobulillar *In Situ* (CLIS):** Esta modalidad enraíza su deformidad genética internamente, de manera exclusiva intra-lobulillar. Pese a utilizar la palabra "Carcinoma", el dictamen patológico moderno rehúsa clasificarle activamente como una fuerza invasiva limítrofe externa; catalogando su hallazgo incidental como una simple pero innegable marcador de riesgo (ACS, 2023). Es valorado clínicamente no como un ataque biológico cruzado, sino como un vector que avisa fuertemente y multiplica a futuro el choque biológico inminente para gestar masas infiltrantes de alta crueldad.

- **Carcinoma Ductal Infiltrante (CDI):** Históricamente y de manera incontrovertible, el CDI es la morfología diagnóstica responsable de la mayor carga poblacional clínica mundial. Su letal etiqueta de infiltrante florece clínicamente el instante donde el bulto

enfermo burla la cápsula de seguridad del conducto originario y escapa para incrustarse agresiva, irreversiblemente hacia el tejido estromal denso y adiposo exterior (World Health Organization [WHO], 2021). Tal acto celular abre la compuerta que favorece diseminar agentes enfermos usando conductos linfáticos a colonizar órganos vitales.

- **Carcinoma Lobulillar Infiltrante (CLI):** Arrojando un flujo secundario de prevalencia clínica bastante inferior en casuística que la vertiente del conducto ductal, este perfil estructural detona también escondido internamente en las saculaciones esféricas productivas orgánicas, no obstante —al compartir un ADN invasivo— triunfa al romper la pared lobulillar, derramándose para expandir un colonizador celular difuso y silente por todos los tejidos base que conectan el órgano (American Cancer Society, 2022).

2.1.5. Vías de Propagación y Rutas Metastásicas

La ruta destructiva y letal del carcinoma de mama no confluye con la mera infestación física del tejido glandular u orgánico original. Su verdadera peligrosidad estriba sistémicamente en su capacidad biológica, casi parasitaria, de generar diseminación. Este esquema invasivo se concreta cuando las secuencias celulares neoplásicas consiguen infiltrar y vulnerar el torrente vascular venoso o los troncos del sistema linfático. La masa utiliza esta anatomía circulatoria a manera de "carretera interna" para emigrar pasivamente y colonizar de forma imperceptible los órganos vitales ubicados a distancias lejanas, gestando el temido cuadro terminal conocido como metástasis. Bajo un encuadre fisiológico normal, toda la estructura linfática opera y defiende al cuerpo humano fungiendo como un escudo de vigilancia inmunológica ininterrumpida. Su vasta infraestructura vascular tiene la tarea de concentrar y circular la linfa, fluido orgánico cargado de linfocitos enfocado en barrer material celular obsoleto. No obstante, durante los cuadros agresivos oncológicos, esta topografía de defensa termina siendo mecánicamente usurpada por los clones del tumor. Al romper la barrera de los capilares y derramarse a la linfa, la célula atípica viaja de forma directa hacia la estación del ganglio más cercano diminutas membranas enclaustradas que filtran y muerden los componentes hallando subrepticiamente ahí el entorno térmico y orgánico ideal para afianzarse y obligar al tejido sano a multiplicarse en copias malignas propias. Acotado a las proporciones anatómicas de la glándula senos, este drenaje biológico no es aleatorio; obedece incansablemente a rutas y túneles previamente trazados cuya infestación define fielmente el cuadro clínico en etapa de peligro:

- **Complejo Periférico Axilar:** Ejerce el embudo primario topográfico. Recibe casi el total absoluto del tráfico de flujo linfático segregado y exudado por la arquitectura mamaria. Diagnosticar confirmando un arribo visible de cepas malignas a este racimo funge operativamente como la evidencia primigenia incontrovertible de que el tumor principal ya logró brincar de "local hacia regional".
- **Cadenas de Relevo Supraclavicular e Infraclavicular:** Se comprenden de aglomeraciones u organizaciones ganglionares incrustadas y alojadas en los bordes y el bajo relieve superficial del hueso de las clavículas. Representando estaciones de choque muy posteriores o ya terminalmente avanzadas de las venas de drenaje; confirmar un enraizamiento aquí es directamente el dictamen inapelable indicando etapa tardía e invasión orgánica sistémica lejana.
- **Eje o Cadena de la Mamaria Interna:** Alojados a un nivel de profundidad casi interpulmonar, flanqueados y arrinconados contra la parte media del esternón. Su alta condición resguardada y escasa accesibilidad anatómica hacen que, de sufrir impacto oncológico infeccioso, representen el marcador radiológico límite agudo necesario para visualizar a qué grado biológico alcanzó a infiltrar u horadar el foco tumoral primario de forma seccional interna el tórax de la mujer.

La imperativa observancia y disciplina quirúrgica de rastrear cepas patológicas a lo largo de este mapa oculto no obedece a formalismos simples, pues existe una correlación de riesgo totalmente lineal y agresivamente destructiva avalada internacionalmente: entre masivo se compruebe el número o aglomerado de nodos linfáticos contagiados, crece por asfixia y estadísticamente el riesgo inminente y la abrumadora probabilidad general de documentar escondidas formaciones de micrometástasis silentes anidando a un mediano plazo en vértebras, pulmones orgánicos o hígado de la paciente (Harris, 2024).

Ante la contundencia de dicho sesgo biológico, agotar todo medio para la evaluación invasiva de la axila iniciando conservadoramente mediante la punción exploratoria y rastreo del mapeo isotópico del ganglio "centinela" u operando masivamente el raspado mediante una disección axilar quirúrgica prevalece actualmente a la par como la pauta o el estándar terapéutico de rigor absoluto e inquebrantable. El veredicto final extraído por medio de este violento bisturí hospitalario excede la tarea de estribar la progresión numérica, sino que dota y traza íntegramente de facto la brújula y

el agresivo paso subsiguiente paramédico oncológico total obligando cuando se corrobore invasión general a desatar una abrumadora guerra biológica total acudiendo urgentemente a las sesiones focalizadas ineludibles de quimioterapia aguda o radio-ablación controlada con aras de inhibir un retorno o recurrencia inoperable (American Cancer Society, 2023).

2.1.6. Modalidades Clínicas de Detección y Diagnóstico

Abatir las altas tasas de mortalidad asociadas al carcinoma mamario exige desplegar una estrategia preventiva multidisciplinaria. Debido a la comprobada heterogeneidad biológica de los tumores, el sistema hospitalario y oncológico nunca deposita su confianza en un único instrumento, sino que articula toda una batería escalonada de modalidades de imagen cruzada y comprobación histológica (American Cancer Society, 2022). Esta matriz de herramientas se desglosa a continuación:

2.1.6.1.Mamografía Digital

La radiografía de la glándula senos se mantiene inamovible como la primera línea de defensa y el recurso metodológico por excelencia para el tamizaje poblacional masivo. Su principio técnico el cruce de radiación ionizante de dosis moderada a través del tejido logra visibilizar aquellas microcalcificaciones aglomeradas en etapa preclínica que resultan biológicamente indetectables bajo simple inspección o palpación manual.

Operativamente, la captura exige aplicar una compresión mecánica controlada al seno mediante placas de metacrilato. Aplanar la estructura es ineludible para minimizar la dispersión de los rayos X, inmovilizar el movimiento por respiración del paciente y garantizar resoluciones de nitidez absolutas en la película virtual. A fin de cubrir todo el mapeo, el protocolo dicta capturar la imagen bajo dos ángulos estandarizados: la proyección Cefalocaudal (CC), arrojando una lectura radial de arriba-abajo, y la Medio-Lateral Oblicua (MLO), que cruza una diagonal profunda para revelar los rincones ocultos desde la axila interna bajo el pecho.

A nivel de intervención civil, el uso de esta herramienta se ramifica. Existe la Mastografía de Detección (*Screening*), impuesta anualmente a mujeres a partir de su cuarta década como rutina preventiva ante la ausencia de síntomas. En segundo término, y frente a quejas directas o bultos palpables durante una revisión de triaje, se activa la Mastografía Diagnóstica, la cual permite

incidir con aumento o *zoom* focalizado directamente sobre la anomalía visual, véase en la Ilustración 5 un ejemplo de una mastografía digital (Instituto Nacional del Cáncer, 2017).

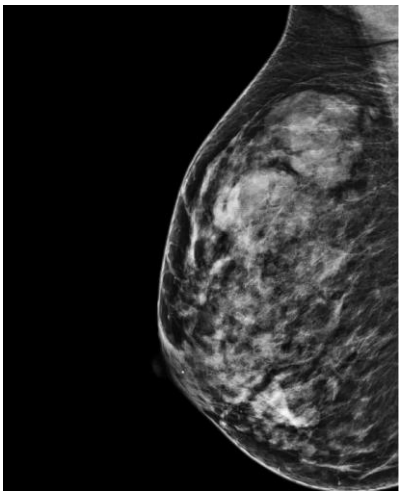


Ilustración 5: Mamografia Digital, Fuente: Instituto Radiodiagnostico

2.1.6.2. Tomosíntesis Digital de Mama (DBT

La ecografía mamaria utiliza ondas sonoras para crear imágenes del interior de las mamas. A menudo se usa como complemento de la mamografía, especialmente cuando se observan masas en mujeres jóvenes o en aquellas con mamas densas. A diferencia de la mamografía, la ecografía no utiliza radiación, lo que la convierte en una opción más segura para ciertas situaciones, como en el seguimiento de hallazgos benignos en mujeres jóvenes. Es particularmente útil para diferenciar entre quistes sólidos y líquidos, ya que los quistes llenos de líquido son generalmente benignos, mientras que las masas sólidas pueden ser tanto benignas como malignas. Este tipo de estudio, que se muestra en la Ilustración 6, también es utilizado para guiar procedimientos como las biopsias mamarias, donde se extrae una muestra de tejido para análisis adicional.

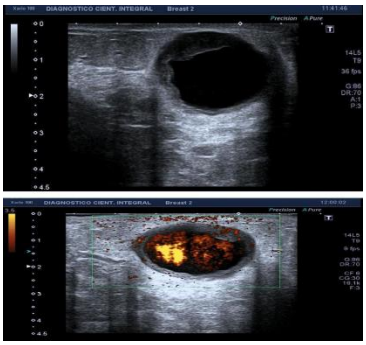


Ilustración 6: Ecografia Mamaria: Fuente: Revista Sintesis

2.1.6.3. Ecografía Mamaria (Ultrasonido)

La resonancia magnética (RM) es una técnica avanzada que utiliza campos magnéticos y ondas de radio para crear imágenes detalladas de los órganos internos. En el contexto del cáncer de mama, la RM se utiliza generalmente en mujeres con un alto riesgo genético (como las portadoras de las mutaciones BRCA1 o BRCA2), mujeres con antecedentes familiares de cáncer de mama o para evaluar la extensión de la enfermedad en mujeres diagnosticadas con cáncer de mama (American Cancer Society, 2022).

La RM de mama tiene la ventaja de detectar tumores pequeños que pueden no ser visibles en la mamografía o la ecografía, especialmente en mujeres con mamas densas. Además, es útil para evaluar la extensión del cáncer en el seno y la evaluación del músculo pectoral en caso de que el cáncer haya comenzado a invadir tejidos cercanos.

Sin embargo, la resonancia magnética tiene una tasa más alta de falsos positivos que la mamografía, lo que puede llevar a más biopsias innecesarias y a la ansiedad de las pacientes. Además, la RM no se utiliza como una herramienta de detección primaria, sino como un complemento para casos específicos. La Ilustración 7, muestra una tomografía hecha para un estudio de mama real.

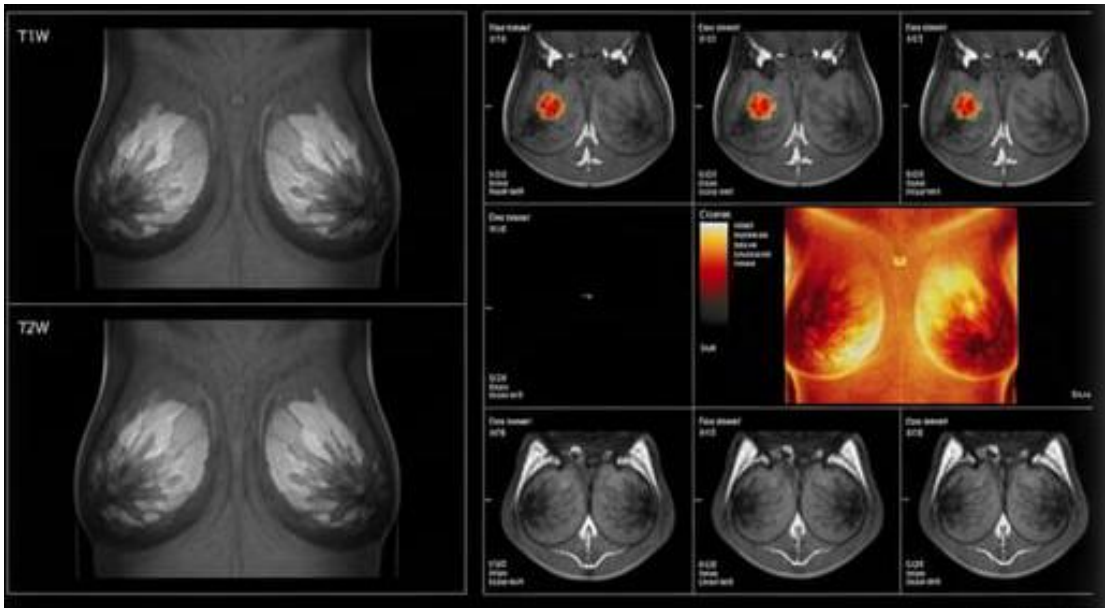


Ilustración 7: Resonancia Magnética de Mama, Fuente: Clínica Prevén

2.1.6.4. Biopsia

Cuando una mamografía, ecografía o resonancia magnética revela anomalías que sugieren la presencia de un tumor, es necesario realizar una biopsia para confirmar el diagnóstico. La biopsia es el único método definitivo para diagnosticar el cáncer de mama (American Cancer Society, 2022) Existen varios tipos de biopsias:

- **Biopsia con aguja fina (BAF)**: Se utiliza una aguja delgada para extraer una pequeña muestra de tejido de la masa sospechosa. Es menos invasiva y se realiza bajo anestesia local.
- **Biopsia por aspiración con aguja gruesa (BAG)**: Utiliza una aguja más gruesa para obtener una muestra de tejido más grande que se examina en el laboratorio.
- **Biopsia quirúrgica**: Si los métodos anteriores no proporcionan suficiente material o si se necesita un análisis más detallado, puede ser necesaria una biopsia quirúrgica, donde se extirpa toda la masa o una porción de ella.

2.1.6.5.Tomosíntesis Mamográfica

La tomosíntesis mamográfica o mamografía 3D que se visualiza en la Ilustración 8, es una tecnología avanzada que crea una serie de imágenes tridimensionales del tejido mamario. A diferencia de la mamografía convencional, que solo toma dos imágenes, la tomosíntesis permite obtener múltiples capas finas de imágenes que pueden ser reconstruidas en una imagen tridimensional. Esta técnica mejora la capacidad de detectar tumores en mamas densas y reduce la tasa de falsos positivos (Friedewald, 2014).

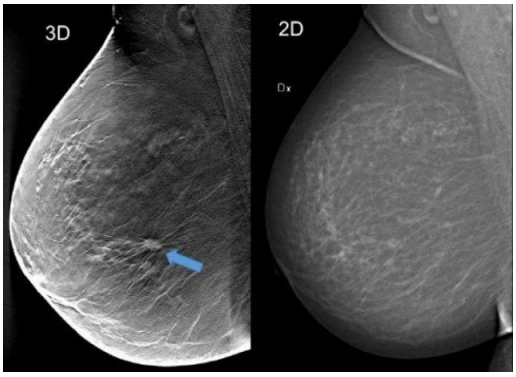


Ilustración 8: Tomosíntesis Mamográfica, Fuente: MedImagine

2.1.6.6.Tomografía por emisión de Positrones (PET)

La tomografía por emisión de positrones (PET) es una técnica de imagen que utiliza sustancias radiactivas para evaluar la actividad metabólica de las células. En el contexto del cáncer de mama, la PET se utiliza para detectar metástasis o la extensión del cáncer a otros órganos. La PET-CT combina la PET con la tomografía computarizada (CT), lo que proporciona imágenes detalladas de las estructuras anatómicas junto con la información funcional sobre las células tumorales (El-Haddad, 2013). Obsérvese la Ilustración 9.

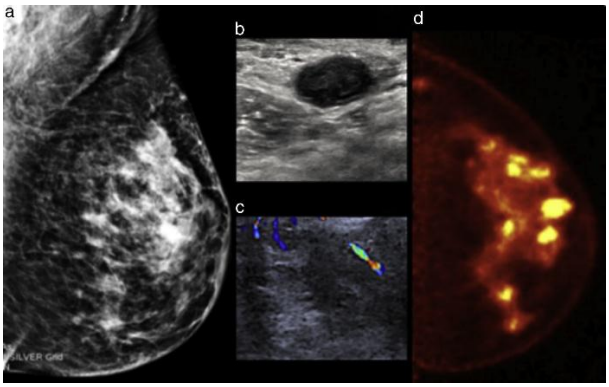


Ilustración 9:: Tomografía por Emisión de Positrones, Fuente: Elsevier

2.1.6.7.Imágenes Fotoacústicas

Las imágenes fotoacústicas combinan la ultrasonografía y la iluminación óptica para obtener imágenes de alta resolución del interior del cuerpo, como se muestra en la Ilustración 10. Esta técnica emergente ha mostrado un gran potencial en la detección de tumores mamarios, ya que permite una visualización detallada de las estructuras internas de las mamas con una alta resolución espacial (Wang, 2012). La combinación de fotones y ultrasonido ofrece ventajas significativas sobre otras técnicas de imagen, especialmente en términos de profundidad de penetración y resolución temporal.

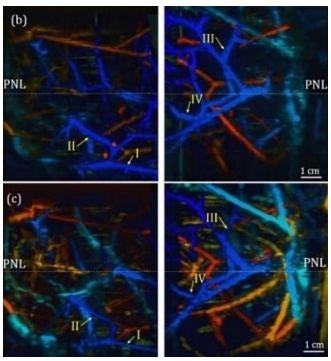


Ilustración 10:: Imágen Fotoacustica de mama, Fuente: MedImagine

2.1.6.8. Tomografía computarizada (CT)

La tomografía computarizada (CT) no es un estándar de detección en cáncer de mama, pero se utiliza en algunos casos para la evaluación de metástasis o para obtener imágenes detalladas del cuerpo en cánceres avanzados. La CT ofrece una imagen tridimensional de los tejidos corporales, lo que puede ser útil en el seguimiento de pacientes con cáncer de mama para evaluar la extensión del cáncer (El-Haddad, 2013).

El análisis del tejido extraído, tal como lo muestra la Ilustración 11, determina si las células son benignas o malignas. Si se detecta cáncer, también se analiza el tipo de tumor, su grado, y la presencia de receptores hormonales (estrogeno y progesterona), lo que ayuda a decidir el tratamiento adecuado.

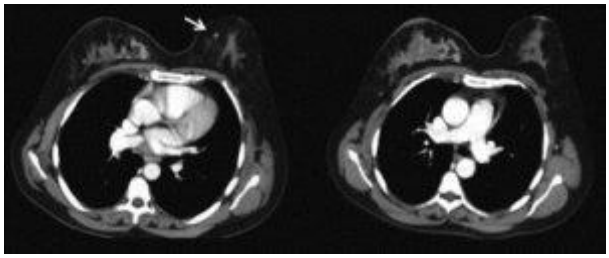


Ilustración 11: Tomografía Computarizada, Fuente: Carlos V. CESUR

2.1.7. Sistema BI-RADS: Estandarización y Léxico Radiológico

El Sistema de Análisis y Reporte de Imágenes Mamarias (*Breast Imaging-Reporting and Data System*, comúnmente conocido por su acrónimo BI-RADS), gestado normativamente y mantenido de forma activa por los comités rectores del Colegio Americano de Radiología (ACR), constituye en la actualidad el estándar clínico global inquebrantable para la interpretación, reporte formal y consolidación de bases de datos imagenológicas del seno. Tal y como lo señala Birdwell (2021) analizando las estipulaciones de la quinta edición del atlas radiológico, el objetivo fundacional de este esquema trasciende pragmáticamente la mera catalogación operativa de nódulos sospechosos o lesiones; la arquitectura intelectual del sistema busca homogenizar el glosario radiológico a fin de amputar desde la raíz la ambigüedad humana observacional, unificar severamente los criterios diagnósticos entre instituciones a nivel mundial, fijar de forma indiscutible el manejo quirúrgico recomendado y propiciar la minería de bases de datos biomédicas altamente estructuradas y auditables.

La profundidad conceptual del mandato BI-RADS se ha visto iterada y enriquecida generacionalmente en concordancia con los hitos ingenieriles. Diseñado en su cuna técnica en 1993 y atado de manera exclusiva en aquel entonces a las proyecciones mastográficas mecánicas de placa, el protocolo fue catapultado gracias a pioneros mundiales como Ellen B. Mendelson y Edward A. Sickles, quienes fungieron como ejes para lograr su metamorfosis expansiva técnica. Su influencia logró calibrar el rigor del estándar para homologarlo a los desarrollos fotométricos secundarios de años recientes —principalmente las modalidades de evaluación por ecografía acústica y el rastreo por resonancia magnética (Mendelson et al., 2013; Sickles et al., 2013)—, logrando formalmente que el léxico diagnóstico ofrezca una valiosa e indisoluble correlación multimodal sinérgica.

Vista desde un plano informático moderno y apegada estrictamente a la visión funcional algorítmica de la presente tesis, esta escala tipificada ejerce la piedra angular biológica y el marco matricial estricto sobre el cual orbita el *ground truth* (matriz de referencia u "oráculo") del proyecto. El sistema BI-RADS dota a la ingeniería de un mapa lógico normativo a partir del cual, ya no solo el médico radiólogo en cabina se apoya, sino que suministra al modelo de Inteligencia Artificial (*Píxel Med AI*) una pirámide de categorización clínica empírica, inmodificable y parametrizada, ideal para sustentar y defender matemáticamente sus reconocimientos infalibles de malignidad.

2.1.7.1. Diagnóstico Estructural de la Glándula (Densidades Mamográficas ACR)

De forma anticipada a iniciar la búsqueda o cacería focalizada de anomalías individuales ocultas (tales como microcalcificaciones en agrupamiento o nódulos sombreados), las directrices del canon BI-RADS exigen asentar inquebrantablemente la conformación arquitectónica global de la paciente. El parámetro clínico denominado "densidad mamográfica" tasa geométricamente y de forma visual la colisión o proporción fisiológica que predomina internamente entre la red de tejido fibroglandular (representado fotométricamente mediante densos bloques radiopacos color blanco brillante) frente a las vastas reservas orgánicas de tejido adiposo o graso neto (trazado inversamente bajo figuras biológicas radiolúcidas arrojadas sobre las franjas de un gris penetrante).

Tal y como estructuraron originalmente (Shickel, 2018), descifrar este esquema tisular requiere someter a la usuaria a una estratificación normada basada analíticamente en cuatro grandes categorías. Comprender a cuál división pertenece la masa glandular determinará contundentemente el umbral de penetración visual, avisando al perito —y, en contextos computarizados, al algoritmo lógico o Inteligencia Artificial entrenada— qué tan alto será su riesgo de sufrir "ilusiones ópticas o cegueras" ante masas escondidas por el grosor subyacente de la placa:

- **Tipología Grado A (Dominancia Tisular Adiposa):** En su nivel matricial primario, evidencian un seno edificado casi en un porcentaje absoluto obedeciendo a la inactividad natural del tejido adiposo blando. Desde la lente restrictiva del dictaminador, el riesgo físico u obstrucción óptica real para que se gesten nubes que intenten enmascarar prematuramente el brote de patologías tumorales incipientes es casi o del todo nulo.

- **Tipología Grado B (Densidades Fibroglandulares Dispersas):** La arquitectura biológica de estas pacientes exhibe caprichosos islotes o parches esporádicos esparcidos densamente asimétricos intercalados por debajo y sobre la capa de la grasa. Resguardando una ligera interrupción sobre la homogeneidad visual base que presenta el seno sano, estas turbulencias ópticas normalmente carecen de la aglomeración fibrosa perjudicial suficiente para torcer u obstruir el reconocimiento y dictamen definitivo de los focos malignos.

- **Tipología Grado C (Configuración Densa Heterogénea):** Para este estrato demográfico o nivel celular altamente peligroso e impredecible, las manchas intrusivas fibroglandulares gozan ya de una ramificación abundante esparcida y profundamente invasiva carente de fronteras espaciales exactas, abatiendo la lectura u opacando en gran parte la visión global en su contra. Su mayor y destructiva amenaza recae orgánicamente sobre el "efecto de enmascaramiento activo" (*masking effect*); siendo capaces de esconder accidentalmente o envolver visualmente los focos de neoplasias oscuras valiéndose de empatar o copiar sin querer el blanco idéntico a las redes estromales nativas del cuerpo humano.

- **Tipología Grado D (Barrera de Densidad Extrema):** Asentándose indiscutiblemente como el máximo reto interpretativo de frustración clínica. La dureza fotográfica generada por la maraña espesa interconectada celular del entramado puro fibromuscular castiga dramáticamente reduciéndolo del todo al piso de sensibilidad estadística probada que dota

genéricamente un test mastográfico radiológico básico frontal de rayos X. Debajo de sus inescrutables mantos tisulares blancos densos, gravísimas heridas agresivas biológicas altamente mortales de carácter puramente paramétrico isodenso, se escabullen y subsisten tranquilamente de forma mimetizada e indivisible, orillando desesperadamente y sin duda a abandonar toda fe ciega depositada metodológicamente y de modo analógico a la primera toma general obligándonos a derivar inmediatamente la cacería de sospechas recurriendo al análisis y auxilio clínico tridimensionales secundarios como recurso vital final de evaluación extrema paralela.

2.1.7.2.Geometría y Descriptores de Hallazgos (Léxico Visual)

En el escenario práctico donde el mastógrafo revela una alteración tisular, la normativa BI-RADS prohíbe el uso de descripciones subjetivas, imponiendo a cambio un glosario de "descriptores invariantes". El conocimiento estricto de este léxico es imperativo bio-informático, ya que representa las entidades u objetos específicos que el algoritmo computacional deberá rastrear. Esta familia de marcadores se segmenta en las siguientes directrices:

Nódulos y Masas (Tridimensionalidad) Clínicamente, se define como "masa" a cualquier invasión tridimensional que evidencie ocupación de volumen constante a través de dos o más ángulos de proyección radiográfica. Su valoración exige deconstruir tres pilares geométricos:

- **Geometría de Forma:** Oscila desde márgenes inofensivos (comúnmente las siluetas *ovaladas* o esféricas obedecen a un comportamiento predecible y benigno, como un fibroadenoma), hasta la forma caprichosa *irregular*; cuyo desorden arquitectónico dota a la zona de un elevadísimo Valor Predictivo Positivo (VPP) asociado a tumoración.

- **Contorno de Margen:** Catalogado como el vector predictor más agresivo del nódulo. Se mapea en una escala de claridad: desde el *circunscrito* (el nódulo presenta un muro limítrofe abrupto e impecable frente al tejido que lo rodea) y el *oscurecido* o *indistinto* (la frontera celular desaparece, insinuando una fuga o desborde local), hasta llegar al nivel de máxima alerta: el margen *espiculado*. Este último dibuja líneas de tensión irradiando como estrellas desde el centro, consolidándose como el infalible sello visual estelar del carcinoma invasor.

- **Densimetría Analógica:** Ejecutada al tasar el contraste radiográfico que opone la lesión frente al tejido natural análogo que la flanquea. Las categorías abarcan un estrato de baja atenuación, isodenso (idéntico) y la letal *alta densidad*. De acuerdo con los paneles directivos documentados por D'Orsi (2013), la sumatoria de una masa sólida fuertemente hiperdensa arrastra abrumadoras sospechas de etiología neoplásica grave.

Familias de Depósitos Cálcicos Las microcalcificaciones son remanentes o depósitos microscópicos minerales atrapados orgánicamente. Su extrema relevancia radica en que fungen a menudo como la precursora —y, a veces, la única— alerta visual temprana antes de detonar un carcinoma ductal franco o estatus de *Comedocarcinoma*. El canon las aísla cruzando su topografía espacial contra su dibujo morfológico formativo:

- **Configuraciones Típicamente Benignas:** Consisten ordinariamente en macro-depósitos (minerales gruesos y redituables). Engloban morfologías inocentes como el esquema "palomita de maíz" (remanente de nódulos cicatrizados viejos), cáscaras de huevo, líneas de "vía de tren" vasculares, y depósitos esféricos de pared radiolúcida central.

- **Morfologías de Sospecha o Escala de Riesgo:** Exigen el ápice del enfoque del radiólogo. Se agrupan bajo rangos de peligro que escalan desde las motas *Amorfas* (polvo sin cuerpo distinguible) y las *Toscas Heterogéneas* (calcificaciones de .5 mm convergiendo juntas), hasta los letales escenarios de aglomerados *Finos Pleomórficos* (esquemas puntiagudos simulando polvo de vidrio quebrado, índice de alto riesgo contundente) y agrupamientos de tipo *Linear Ramificado* (calcio acumulado rellenando fielmente las grietas de la ductalidad terminal extirpada por necrosis severa). El riesgo de estos fragmentos multiplica su grado de ataque si radiológicamente se exhiben agrupados en *racimos o cúmulos difusos* sobre áreas volumétricamente concentradas (típicamente >5 depósitos concentrados en esferas de apenas 2 mm).

Asimetrías y Distorsiones Relativas Comprendidas como aquel volumen asimétrico de masa fibroglandular discordante al ser contrastado contra su glándula mamaria opuesta "espejo", no obstante, sin lograr concretar una masa cimentada sólida con geometría física. Estas sombras estructurales varían desde la *Asimetría Simple/Global* (voluminosidad mamaria asimétrica

inofensiva) y la *Focal* (sombra anómala acotada), hasta la temida *Asimetría en Desarrollo*. Esta última conforma aquel engrosamiento atípico oscuro nunca antes registrado en el historial radiográfico viejo de la mujer, conjeturando biológicamente una malignidad encubierta floreciendo activamente (Sickles et al., 2013). Adicionalmente, el documento final no omite hallazgos periféricos vinculantes que refuercen diagnósticos; tales como *distorsión focal pura sin masa visible del centro al pezón*, abultamiento de dermis, o marcados colapsos (retracciones) arquitectónicos axilares.

2.1.7.3. Geometría y Descriptores de Hallazgos (Léxico Visual)

Con la labor hermenéutica del léxico visual concluida, el perito humano (o nuestro modelo algorítmico IA análogo) requiere asentar jurídicamente una categorización definitiva o dictamen numérico. Este índice estandarizado escala universalmente del grado cero al seis, dictando inequívocamente la temporalidad del manejo clínico mandatorio adyacente:

- **Nivel 0 (Escrutinio Inconcluso - Llamado a Complemento):** El bloque analítico aborta el dictamen definitivo argumentando información deficiente u omisión técnica de visibilidad. Fisiológicamente la placa original es inoperante, demandando someter a la mujer de emergencia extrema a barridos ecográficos paralelos alternativos o microfocos con mayor comprensión focal para solventar dudas.
- **Nivel 1 (Ausencia de Hallazgos - Negatividad de Riesgo):** Condición orgánica óptima. Las placas devuelven una simetría tisular estructural impoluta. Representa matemáticamente un VPP de malignidad comprobable absoluto de 0%.
- **Nivel 2 (Conformación Benigna - Sin Riesgo Patológico):** Placas con abultamientos demostrables o anomalías palpables comprobadas bio-estructuralmente como material carente de amenaza (p. ej. calcificaciones tipo "macro" secretorias pasivas, quistes simples sellados de aceite, o micro-senos preexistentes inertes). El VPP de malignidad permanece estadísticamente nulo (0%), delegando a la mujer al programa gubernamental conservador rutinario poblacional de un a tres años.

- **Nivel 3 (Posible Benignidad - Susceptibilidad Sub-clínica):** Umbral probabilístico catalogado comúnmente en la industria oncológica con riesgos menores contundentes de VPP por debajo o igual al 2% (≤2%). Sin embargo, la mínima duda morfológica de la mancha exige no descartar ni despachar a la paciente; demandando estrictamente recortar la vigilancia reduciéndola a someterle en placa continua durante ciclos acelerados de seis meses hasta certificar estabilización nula.

- **Nivel 4 (Presunción Tumoral - Protocolo Biópsico Mandatorio):** El dictamen colapsa arrojando imágenes o conjuntos de distorsiones visuales perturbadoras (tales como microcalcificaciones pleomórficas agrupadas con base irregular). Clínicamente el doctor interrumpe rastreos preventivos pasivos para someter o referir imperativamente bajo el bisturí patológico con el mandato inexcusable de ejecutar una biopsia de verificación y confirmación histopatológica. Basado en su probabilidad creciente de invasividad biológica, el piso numérico subdivide y pondera al nivel en tres subgrupos biológicos operables progresistas: 4A (Sospecha Moderadamente Baja de 2-10%), 4B (Riesgo Estadístico de 10-50%) y por último el 4C (Riesgo Subyacente Alto de 50-94%).

- **Nivel 5 (Alto Vector de Convicción/Cáncer Invasivo Esperado):** Categoría cuasi-terminal donde se evidencia en la primera línea o pantalla visual un hallazgo clínico que proyecta la "huella genética del cáncer incuestionable" (generalmente masas densas de trazos estelares espiculados destructores de tejido denso base). La confirmación de malignidad roza en esta cota umbrales devastadores (VPP clínico real del >95%), prescribiendo una extracción de biopsia por protocolo confirmatorio y preparando simultáneamente el domo oncológico hospitalario inmediato radiológico quimioterapéutico drástico en espera del tejido arrojado.

- **Nivel 6 (Verificación Histológica Previa - Condición Controlada):** Clasificación de exclusión ajena a diagnósticos nuevos primigenios o *screening*; otorgada meramente de facto para identificar y evaluar placas oncológicas donde el carcinoma ya superó y documentó plenamente con acta de biopsia quirúrgica la certeza histológica.

El uso de BI-RADS también facilita el seguimiento continuo de las pacientes con hallazgos sospechosos o benignos, permitiendo a los profesionales de la salud tomar decisiones informadas sobre el manejo de los pacientes a lo largo del tiempo. La clasificación BI-RADS también facilita la comparación de resultados a largo plazo en estudios multicéntricos y la

evaluación de la eficacia de los programas de detección, en la Figura 3 se puede observar gráficamente como está jerarquizada la clasificación de BIRADS.

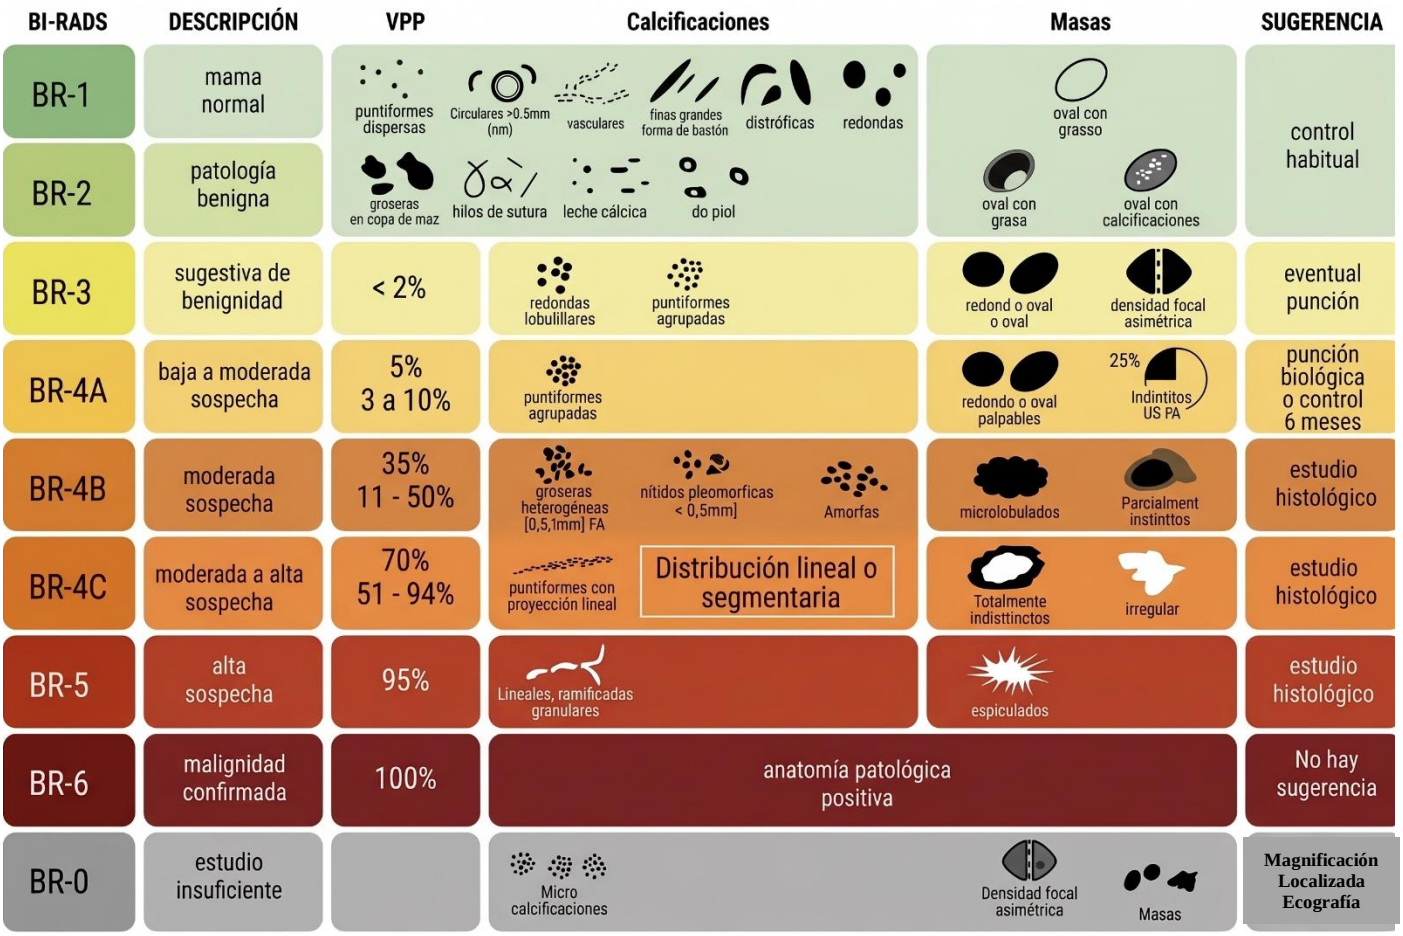


Figura 3: Clasificación de BIRADS Jerarquizada, Fuente: Rostagno 2019

2.1.7.4. Importancia del diagnóstico temprano en el Cáncer de Mama

El pilar estructural para lograr abatir la letalidad endémica de esta patología no reside exclusivamente en la agresividad de las terapias radio-quirúrgicas posteriores, sino en la capacidad clínica de dominar la recolección temprana de anomalías. A nivel estadístico, cuando un foco neoplásico es satisfactoriamente interceptado en sus ventanas orgánicas de maduración incipiente (clasificadas como cuadros preclínicos *in situ* o la Fase I del tabulador de riesgo), la base de datos oncológica mundial avala un horizonte de sobrevida probabilístico en la paciente con proyecciones positivas superiores al 90% tras superar la típica franja crítica de los cinco años. Con evidente polaridad inversa, un hallazgo extemporáneo merma y colapsa drásticamente estas proyecciones, principalmente motivado por la diseminación inevitable y pasiva del cáncer

a otros órganos contiguos, aunado a la escasa asimilación terapéutica del paciente ante recursos biológicos ya muy mermados.

La cultura del seguimiento de los factores de riesgo y el éxito del diagnóstico temprano conviven en una estrecha simbiosis operativa. Si bien un perfil alto de alerta suele empujar a las mujeres a no saltarse su cronograma de estudios mastográficos, en el escenario operativo de los sistemas de salud pública latinoamericanos y muy marcadamente en la distribución institucional de México prevalecen incontables bloqueos metodológicos (Arnold, 2022). Factores que oscilan entre negligencias por estilos de vida modificables, hasta la cruda realidad que representa una severa escasez tecnológica y el déficit irrefutable de cobertura por parte peritos radiólogos certificados en zonas no metropolitanas. Dicho cuello de botella en los hospitales y centros de salud se traduce tristemente en la imposibilidad logística de analizar oportunamente las placas, encauzando que multitud de diagnósticos retrasados se emitan cuando los carcinomas ya transitaron silenciosamente hacia rangos indetenibles.

Buscando extirpar de raíz ese cuello de botella humano y técnico, la inserción programada de Sistemas de Soporte a la Decisión Clínica (a través de sus siglas CDSS) alimentados mediante Inteligencia Artificial despunta como la contramedida más prometedora. Para aquellos escenarios logísticos marcados por un acceso institucional limitado a la cúpula de médicos subespecialistas, amalgamar ecosistemas algorítmicos (como las matrices convolucionales de aprendizaje profundo en la lectura de expedientes) suple y complementa de inmediato esa carga de revisión visual intensiva. Estas arquitecturas de código ostentan hoy la perspicacia y potencia escalar matemática requerida para atrapar morfologías ocultas altamente caprichosas a los ojos de un humano cansado; arrojando una veloz y acertada segunda opinión empírica que rescata al dictamen temprano e inflaciona drásticamente los márgenes de supervivencia civil. (Arnold, 2022).

2.1.7.5. Normativa Probabilística ACR BI-RADS y el Consenso Colima 2025

La "Normativa probabilística ACR BI-RADS" se refiere al enfoque adoptado por el Colegio Americano de Radiología (ACR) que vincula explícitamente cada categoría diagnóstica con un Valor Predictivo Positivo (VPP) estadístico o probabilidad matemática de cáncer. Este marco no solo etiqueta las imágenes, sino que dicta decisiones algorítmicas basadas en el porcentaje de riesgo (ej., <2% para BI-RADS 3; >95% para BI-RADS 5).

Para garantizar que el modelo de Inteligencia Artificial (Píxel Med AI) y su salida diagnóstica no solo cumplan con el estándar internacional de la ACR, sino que se ajusten operativamente a las necesidades del sistema de salud nacional en México (como el IMSS), el sistema basa sus lineamientos clínicos en el **Consenso Colima 2025**. El Consenso de Colima sobre Cáncer de Mama (2025) es la guía médico-oncológica más actualizada y avalada por expertos mexicanos. Dicho documento adapta las directrices del tratamiento quirúrgico, la criba y el diagnóstico oportuno a la realidad institucional de los hospitales de la República Mexicana, regulando legal y médicamente el flujo de atención para las pacientes desde el momento de la detección radiológica. Integrar ambas normativas permite que el sistema proporcione una segunda opinión justificada, técnica y probabilísticamente respaldada para el entorno local.

2.2. Tecnologías en el diagnóstico de imágenes médicas.

2.2.1. Definición y Paradigma de la Inteligencia Artificial Oncológica.

Dentro del crisol vanguardista de las ciencias de cómputo, la Inteligencia Artificial abandonó hace décadas el concepto obsoleto del software lineal o programado por reglas fijas; erigiéndose en la actualidad como un inmenso campo algorítmico basado en redes o funciones matemáticas enfocadas a emular y simular con éxito heurísticas deductivos procesos reflexivos de razonamiento, aprendizaje no supervisado y toma de decisión que previamente se consideraban facultades exclusivas o inherentes de la percepción humana (Russell, 2016). El músculo principal para lograr esta asombrosa autonomía intelectual radica en el subcampo metodológico del Aprendizaje Automático (*Machine Learning*). A través de inyectarle e instarlo a procesar colosales volúmenes de datos empíricos, estos métodos no aguardan estáticamente instrucciones programadas por un humano, sino que extraen correlaciones subyacentes, auto-calibran su margen de error y dictaminan hallazgos de forma autárquica.

Como estandarte indiscutible y cúspide de esta pirámide evolutiva resalta el *Deep Learning*. En esta vertiente, el entrenamiento analítico básico se deja atrás para pavimentar el despliegue tridimensional de densas mallas bautizadas como Redes Neuronales Artificiales. Dichas agrupaciones matemáticas profundas particularmente aquellas diseñadas en laboratorios para resolver retos topográficos o de visión ostentan la capacidad superdotada de "ingerir" masivamente millones de píxeles gráficos; reconociendo y extrayendo de forma escalonada texturas y morfologías microscópicas que le resultarían francamente invisibles y crípticamente confusas a la simple óptica de un evaluador humano.

Acotando este poder de cálculo hacia el ecosistema de la medicina moderna, resulta evidente que las infraestructuras hospitalarias se están ahogando en la necesidad actual de cruzar registros clínicos masivos e imágenes de alta densimetría. Como bien dictamina en la literatura (Shickel, 2018), la adopción técnica de tensores neuronales ha revolucionado la fiabilidad del diagnóstico, al dotar a los pabellones de medicina predictiva que amalgaman la precisión milimétrica del algoritmo con la gestión del pronóstico individual de cada paciente.

Es primordialmente en esferas carentes de margen de error —como el abordaje radio-oncológico evaluando una mastografía— donde esta herramienta logra un pico de rentabilidad indiscutible. Debido a su inmunidad física total frente a la fatiga ocular, el modelo artificial barre los mapas de contraste a nivel de bit crudo arrojando mallas retro-iluminadas de certeza probabilística abrumadora. Finalmente, y por dictamen bioético inamovible, la IA contemporánea en nuestro país no pretende fungir ni implementarse simulando desplazar de alguna manera al personal subespecializado del hospital; su desarrollo asume el papel perimetral de integrarse exclusivamente a laborar como un escudo o andamiaje validado de Segunda Opinión. Esta maquinaria filtra anomalías densas en fracciones del reloj para destacar los posibles focos malignos, y delega a un paso puramente verificacional la carga para el médico, desterrando implacablemente a casi ceros el temido margen o factor humano propenso a equivocaciones de sesgo por agotamiento físico ante demandas excesivas.

2.2.2. Aplicaciones clínicas de la IA Hospitalaria

La instauración matemática y la asimilación progresiva de la Inteligencia Artificial dentro de las fronteras biológicas no constituye o recae en un evento aislado o un experimento computarizado hermético. Por el contrario, su capacidad matricial adaptativa ha permeado y fracturado decenas de paradigmas médicos longitudinales en años recientes. Lejos de acotarse

netamente a operar tareas teóricas menores en los cubículos de los directivos, el abanico resolutivo de su código abraza hoy los estadios clínicos transversales más cruciales de la paciente: desde vislumbrar y proyectar un rastreo genético encubierto, hasta gobernar cinemáticamente la pinza autómata de titanio que empuña un bisturí microscópico de quirófano en cirugías a cielo abierto. Ponderando analíticamente toda su escalabilidad, la literatura de vanguardia clasifica esta asombrosa penetración biotecnológica bajo cuatro principales esferas radiológicas ingenieriles:

- **Visión Computacional Aplicada a Radio-Imagenología** Acaparando de forma inequívoca o fundacional el peso volumétrico nucleico justificante para el presente documento, el paradigma visual en hospitales ha resucitado enormemente amparado en las familias metodológicas que componen a la Red Neuronal Convolucional. Al transmutar visualizaciones o placas análogas limitadas que devora en profundos y masivos diagramas o mallas matriciales algorítmicas atenuadas, la programación de este tensor matemático desborda una facultad deductiva e inédita formidable enfocada a delatar lesiones incipientes minúsculas o formaciones tisulares destructivas caprichosas, aislando geometrías malignas microcalcificadas con un brillo que el espectro retiniano del ojo humano sano sencillamente fracasaría en atrapar sin equipo (André Esteva, 2017).

- **Genómica Computacional y Análisis de Marcadores de Choque** Aterrizando los recursos a las diminutas escalas del ADN, poderosísimos y pesados modelos de minería o aprendizaje automatizado digieren febrilmente los colosales océanos informáticos

  albergados en datos secuencias proteínicas poblacionales. Este escrutinio sistémico purifica y depura ininterrumpidamente las cadenas, posibilitando extirpar desde sus confines las mutaciones genéticas o rastros ocultos de alerta marcadora preventiva; los cuales presagian a corto plazo el estallido inevitable del cuadro patológico invasor del cáncer frente a sus futuras víctimas biológicas (Collins F. S., 2015)

- **Modelado de Terapias Predictivas en Oncología (Medicina Personalizada)** Trenzando los frágiles datos basales particulares clínicos dictados al ingresar una ficha clínica y empatándolos sin margen de sesgo estadístico analógico frente y contra los perfiles reaccionarios y estadísticos guardados o minados a nivel

general, los procesadores de cálculo predictivo vaticinan asombrosamente exactos la tolerancia corporal biológica real y cálido desempeño curativo.

- **Asistencia Robótica de Precisión Intervencionista** Rompiendo radicalmente las esclusas de existir como un intangible código espectral programado y encarnando su mandato hacia motores eléctricos, la rama matriz algorítmica toma posesión lógica e inyecta gobierno inteligente motriz a docenas de estaciones quirúrgicas o plataformas mecánicas y autárquicas auxiliares operativas. Dotando a estos fríos y milimétricos cirujanos articulados biológicamente carentes de pulso titubeante ni fallos oscilantes bajo estrés, la tecnología ha recortado abrumadoramente traumáticos episodios intraoperatorios o las desproporcionadas tazas en fatalidades postquirúrgicas producto del desgaste humano en cabina, limitando notablemente sus sangrados de paciente mediante sutileza extrema robótica en cada tajo microscópico validado por el escáner al extirpar el nido mamario enfermo (Lanfranco et al., 2004).

2.2.3. Sistemas de Soporte a la Decisión Clínica (CDSS)

Traslapando las abstracciones teóricas del Aprendizaje Automático hacia un recurso hospitalario tangible, la aplicación práctica de estas inteligencias cristaliza bajo la figura de los Sistemas de Soporte a la Decisión Clínica (CDSS, por su acrónimo anglosajón *Clinical Decision Support Systems*). Estas redes de código no operan como simples visores estáticos, sino como ecosistemas intervencionistas integrales nutridos empíricamente. Su tarea nuclear es compilar, cruzar masivamente y tamizar las historias de salud de los pabellones (tales como biomarcadores celulares de laboratorio histopatológico, antecedentes genéticos estocásticos y densimetrías de imagenología radiológica) con el objetivo de emitir recomendaciones lógicas y estadísticamente estratificadas para mejorar el abordaje del paciente.

El diseño bio-legal de un CDSS contemporáneo estipula una premisa ética inquebrantable en todo laboratorio: el software ignora por completo la pretensión de usurpar o sustituir la jurisdicción del diagnóstico médico humano. Su verdadero valor radica en fungir como un "asistente de predicción paramétrica". Aprovechando sus bondades, algoritmos rigurosamente entrenados son capaces de auditar y aislar hoy métricas genéticas para predecir a mediano plazo si un cuerpo aparentemente sano cuenta con los marcadores suficientes para detonar patologías o cáncer, ofreciéndole al galeno un valioso abanico de prevención primaria e intervención oportuna (Alonso et al., 2018).

Aplicabilidad Avanzada de los CDSS en Cáncer de Mama Acotado estrictamente a la matriz fenotípica y radiológica que respecta a la glándula senos, la instauración de una herramienta de decisión algorítmica destila su utilidad práctica fundamentalmente en dos frentes del tratamiento:

- **Tamizaje Visual y Clasificación de Peligro:** Operando de la mano y en paralelo a la consola del mastógrafo, el motor de Inteligencia Artificial evalúa matemáticamente en milisegundos las sombras de calcificación o asimetrías arrojadas en la película radiográfica. Acto seguido, inyecta su predicción empírica recomendando una métrica de sospecha (idealmente bajo la tipificación internacional BI-RADS). Esto otorga una ruta crítica inicial focalizada al especialista civil, instándolo a desviar de forma prioritaria los recursos oncológicos del hospital hacia las mastografías rotuladas con alta probabilidad de malignidad biológica.

- **Predicción de Recurrencia Post-Terapéutica:** Con suma destreza técnica, la Inteligencia Artificial mantiene su vigilancia mucho más allá de la ventana del quirófano o del bisturí clásico asistiendo al oncólogo. A través del aprendizaje automático o *machine learning*, el software prosigue cruzando los registros clínicos y el impacto celular en pacientes consideras "supervivientes"; intentando vislumbrar y predecir el enorme peligro latente de que la patología tumoral guarde fuerzas para un rebrote prematuro a futuro. Modelizaciones computarizadas, como la sometida a censo en la investigación clínica de Buda et al. (2018), le proveen a los departamentos médicos y radiológicos actuales un tabulador asombrosamente fiel sobre la probabilidad estricta de advertir una recaída de cáncer de mama. Dotando con esto, a manera de Segunda Opinión predictiva, el aval moral necesario al médico para someter ineludiblemente a las mujeres a las quimioterapias agresivas, o en su defecto, para otorgar exitosamente las actas de inmunidad a las sobrevivientes de etapa terminal.

2.3. Arquitecturas Algorítmicas para el Filtrado Oncológico Mamario

Abordando los preceptos computacionales a la tarea matricial específica de evaluar e identificar la agresividad patológica de un nódulo mamario, la ingeniería de software actual aborda la resolución de esta incógnita clínica mediante vías algorítmicas dominantes, cuya gran discrepancia técnica radica enteramente en su dependencia hacia la intervención paramétrica previa obligada por parte del desarrollador.

2.3.1. Del Machine Learning Estadístico al Deep Learning Autónomo

Bajo un primer abordaje, el subcampo del Machine Learning clásico proyecta su matriz de diagnóstico confiando y sujetándose a modelados de clasificación matemática muy rígidos. Tradicionalmente opera erigiendo Máquinas de Soporte Vectorial (SVM) enfocadas a trazar "hiperplanos de separación" en un espacio multidimensional que diferencien las células, o a través del barrido de Bosques Aleatorios (*Random Forests*) que fluyen segregando condiciones mediante un esquema estadístico de "árboles de decisión" masivos. El rasgo intrínseco que amarra y limita a estas vertientes en el ecosistema de la mastografía es su debilidad alimentaria por ceguera espacial: las líneas de código de ML exigen forzosamente que el ingeniero médico etiquete y extraiga manualmente las peculiaridades de cada lesión (*Feature Engineering*) antes presentarlas al motor, perdiendo meses en tabulación analógica.

Intentando abolir ese bloqueo limitante, el despliegue moderno de la rama del Aprendizaje Profundo (*Deep Learning*) descarta por completo la pre-extracción manual apoyándose a cambio en el uso de tensores informáticos e iteración por capas sucesivas. Tal y como lo postuló (LeCun, 2015) en la modernización clínica e introductoria del mapeo profundo, al instanciar herramientas biológicamente inspiradas como las Redes Neuronales Convolucionales, el algoritmo de código adquiere capacidades perceptuales plásticas autárquicas y autónomas. La arquitectura programada es capaz de adquirir directamente y sin filtros humanos las radiografías con cruda alta densidad del seno; permitiendo así que el modelo calíbre progresiva y ocultamente por sí solo sus miles de "pesos y sesgos" matemáticos hasta descifrar u abstraer un borde espiculado o una opacidad imperceptible que separe nítidamente a la patología benigna de la infiltrante maligna.

Finalmente, la orquestación e incrustación de estas modalidades analíticas en las cabinas de lectura hospitalaria dista mucho del afán de engendrar un software mecatrónico reaccionario diseñado para suplir al radiólogo o tomar decisiones sin permiso. Tal y como reflexiona (Topol, 2019) analizando la conjunción humanista frente a la medicina de alta tecnología moderna contemporánea; este abordaje computarizado está enteramente enmarcado como un sistema colaborativo de alivio enfocado a mermar operativamente la ingrata e implacable carga o avalancha visual estéril en los pabellones de mastografía. Un recurso informático puro que absorba parte de la demanda y minimice brutalmente la subjetividad derivada inevitable de debilidad biológica o el cansancio derivado del humano frente al monitor tras varias horas de escrutinio, entregando como recompensa civil última un triaje preventivo y curativo democratizado cien veces más veloz contra reloj del cáncer de seno invasor.

2.3.2. Redes Neuronales Convolucionales y Mapeo en Estructuras Tisulares.

Las Redes Neuronales Convolucionales representan una tipología ingenieril altamente especializada de escalamiento y *Deep Learning*. Su topología y arquitectura intrínseca fue concebida matemáticamente de origen para ser capaz de absorber volúmenes topográficos tabulados (tales como la enorme matriz restrictiva de píxeles o la rejilla fotométrica dictaminada en una placa biomédica radiográfica). Inspiradas orgánicamente por preceptos neurológicos —y tal y como quedó demostrado empíricamente en los trabajos computacionales revolucionarios arrojados por (Krizhevsky, 2012), las CNN logran con soberbio éxito emular el rastreo o barrido de cruce jerárquico del córtex o globo visual humano gracias a poseer un sistema oculto de procesamiento algorítmico multicapa.

Bajo una estricta óptica computacional, el engranaje profundo de estas redes no se paraliza intentando almacenar o "memorizar de golpe" la mastografía; su secreto para aprender fluye arrastrando matrices secuenciales de filtros operativos (matemáticamente llamados operaciones de convolución o *kernels*) navegando incesantemente sobre todo el volumen fotográfico del seno mamario con el afán único de extraer mapas de características aisladas. Mientras que en sus estratos computacionales o nodos superficiales primarios la red recoge visualmente apenas los bordes liminares biológicos crudos de la mama y asimila los gradientes cambiantes del brillo; tras aplicar sus funciones matemáticas de reducción y compresión u agrupamiento escalar paramétrico constante (conocido como *pooling*) logra estilar su aprendizaje profundo en la

última recolección neuronal; capacitando plenamente al procesador con destrezas visuales abrumadoras para discriminar en fracciones de tiempo texturas sombreadas complejas, contornos de asimetría celular celular y agrupaciones biológicas microscópicamente crípticas sin intervención de un codificador civil.

2.3.3. Despliegue Operativo y Sensibilidad Diagnóstica en Cáncer de Mama

Acotando la tecnología frente al rastreo de densidades u agresividades dictaminadas ante monitores de mastografía, la matriz puramente convolucional desprende y libera a las áreas clínicas de ingeniería y radiodiagnóstico del rudimentario rastreo del cáncer pixel-a-pixel; inyectando una asimilación cruzada autónoma y veloz para catalogar disrupciones estructurales agresivas sobre un tejido tisular biológicamente invadido. Simulaciones multicéntricas cruzadas (cabe destacar, por ejemplo, los ensayos técnicos oncológicos desplegados por (McKinney 2020)) refrendan el salto computacional: arrojaron bajo esquemas clínicos reales cómo arquitecturas basadas puramente en modelos de red profunda clasificatoria sobrepasaban tajantemente barreras empíricas de especificidad; evidenciando un diagnóstico en placas fotográficas con índices de fiabilidad predictiva de falsedad asombrosamente superior a la pericia de un panel cruzado constituido por médicos radiólogos expertos en la detección de tumores primarios en masa de manera aislada humana presencial.

Puntualmente y gracias a dicho impacto algorítmico paramétrico sin antecedentes en nuestro siglo, la adhesión mecánica de software CNN ante sistemas de hospitales resalta por generar aportaciones colaterales clínicas trascendentales enfocadas a calidad y curación de vida para la población usuaria paciente:

- **Incremento del Foco en Resolución Primaria Estructural:** La línea de exactitud y agudeza sensible paramétrica predictiva escala por encima de percepciones habituales biológicas limitadas, amparando asombrosamente que el equipo logre cazar agrupaciones morfológicas irregulares esporádicas microcalcificadas sin fallar, y diagnosticando sin miedo masas que por su naciente pequeñez sombreada o esfericidad camuflada eludían las pesquisas y detecciones durante estadios de pre-gestación preclínica temprana.

- **Abatimiento Frontal a los Índices Terapéuticos Biopsia-Positivo Falso Físicos (Intervencionismo Agresivo Mermado):** La verificación o purificación continua derivada visual a cargo por la evaluación autárquica informática restringe abrumadoramente las dictaminaciones sobre de falsos focos radiológicos o falsos negativos destructivos orgánicos. Mitigación técnica que salvaguarda operativamente bajo el enfoque práctico oncológico civil hospitalario a exentar la trágica ruta aterrorizada rutinaria ineficaz que encamina o sentencia forzosamente y de forma alarmista innecesaria irresponsable prequirúrgica al paciente ante mutilaciones, punción por aguja dolorosa estéril o ejecución cruenta en cirugías extirpativas sin causa bajo biopsia clínica o mera especulación sospechosa fallida visual en turno de madrugada sin fatiga alguna médica humana en el especialista u operador.

2.3.4. Transferencia de Arquitectura (Transfer Learning) y Curvas de Maduración Paramétrica Inter-Dominio

Entrenar una red neuronal profunda desde cero exige procesar bases de datos masivas para que sus algoritmos puedan converger y aprender a distinguir patrones visuales con precisión estadística. Sin embargo, en el ámbito de la oncología mamaria, recolectar este volumen de información representa un reto logístico severo. La estricta confidencialidad bioética, sumada a las normativas de privacidad del paciente, prohíben la circulación masiva de expedientes radiológicos positivos (Yosinski, 2014). Esta escasez crónica de "datos etiquetados" provoca que desarrollar un modelo utilizando exclusivamente imágenes médicas resulte prohibitivo por el tiempo de cómputo y la falta de material biológico documentado.

Para sortear este bloqueo de información, el desarrollo de software implementa *Transfer Learning*. Esta técnica consiste en importar la arquitectura y los parámetros matemáticos de un modelo que ya fue exitosamente entrenado en un dominio distinto donde sí existía abundancia de datos. Habitualmente, la industria biomédica utiliza algoritmos que procesaron millones de imágenes comerciales de libre acceso publicadas a nivel global (como la base de datos *ImageNet*). La justificación matemática de este método asume que las primeras capas de cualquier red neuronal aprenden patrones físicos geométricamente universales: bordes liminares, claroscuros, ejes y texturas. Estos fragmentos visuales elementales resultan igualmente útiles tanto para identificar objetos convencionales en el terreno informático, como para delinear morfológicamente las curvas patológicas de un tejido mamario.

2.3.4.1.Optimización Fina (*Fine-Tuning*) sobre Redes VGG y ResNet

En el ecosistema analítico moderno, los laboratorios oncológicos evitan rediseñar el código ancla, y a cambio apuestan por la importación de modelos base estandarizados, entre los que destacan de manera imperativa las mallas VGGNet o las arquitecturas espaciales.

Al injertar estos algoritmos preentrenados en la infraestructura local, el desarrollador congela informáticamente las capas primarias (ya experimentadas en rastrear bordes y texturas) y dedica sus recursos exclusivamente a reentrenar de manera sutil las capas finales del modelo de inferencia predictiva. Este proceso, definido en la industria del *Machine Learning* como ajuste fino (*Fine-Tuning*), se alimenta y se nutre ya específicamente del modesto catálogo de mastografías y ecografías patológicas con las que cuente el hospital investigativo. Como resultado, la herramienta consigue estabilizar altas tasas de precisión analítica en el tamizaje de cáncer mitigando de tajo las mermas crónicas derivadas del extenuante entrenamiento autónomo o la asfixiante sequía de la data médica disponible.

2.3.5. Métricas Paramétricas de Validación y Rendimiento Algorítmico.

El pilar inquebrantable para certificar o autorizar la extracción de un algoritmo biológico desde el entorno controlado de laboratorio (*sandbox*) hacia el siempre caótico y hostil ecosistema del piso radiográfico, reposa integralmente en la agresividad de su evaluación estocástica. Un modelo de redes neuronales de oncología jamás es aprobado para liberar diagnósticos apoyándose meramente en simple "intuición visual"; exige un blindaje estadístico estricto sustentado en una matriz de paramétricas matemáticas universales innegociables (Zhou, 2017). En el terreno estricto de la clasificación de mastografías, el rendimiento profundo se disecciona obligatoriamente bajo los siguientes escrutinios de confusión de datos:

- **Sensibilidad (*Recall*) y Especificidad Métrica:** La sensibilidad tabula la eficacia o poder de "cobertura salvadora": define matemáticamente la proporción de mujeres enfermas verdaderas que el código logró aislar exitosamente logrando evadir a las silenciosas y siempre mortales trampas de los "Falsos Negativos". Evaluado como la métrica de excelencia de oro en la prevención clínica, los modelos de IA elevan su *Recall* como una cruzada absoluta, permitiéndose inclusive arrastrar en el camino algunos falsos positivos o alarmas pasivas en pro de abatir al máximo los casos de pacientes que escapan del rastreo celular con cáncer encubierto y se regresan a sus casas sin aviso oportuno médico.

- **Exactitud Transversal (*Precision*) y Malla de Ajuste Armónico Balanceado (*F1-Score*):** En materia puramente informática, la precisión aislada dictaminará y purificará los aciertos directos, tasando estrictamente cuántos de los nódulos iluminados como sospecha clínica en el monitor resultaron biológicamente malignos al enviarse a biopsia real (cortando de tajo al extremo la insidiosa carga y dolor social familiar del "Falso Positivo"). Operativamente la ingeniería suele acudir al cálculo *F1-Score*; proveyendo al programador de un tabulador robusto cruzando e integrando matemáticamente y sin compromisos un estricto empate promedio entre ambas fuerzas analíticas evaluables antes del despliegue masivo.

- **Capacidad Discriminativa Curva ROC y Umbral Subyacente (*AUC*):** Fungiendo finalmente como el "sello jurídico y garantía absoluta" universal del modelo de predicción de Píxel Med dictando o midiendo qué tan perspicaz resultó la asertividad biológica lograda; graficando o contrastando tajantemente el alza o castigo contrapuesto que sufre innegablemente o deviene directamente en la relación algorítmica tras chocar de frente la excelente o impecable recolección lograda verdadera a la par versus los dictámenes alarmantes falsos equivocados; otorgando y dictando su asimilación civil clínica únicamente entre más se logre su área abarcada paramétrica acerque visualmente casi a su cuota estadística estricta absoluta del valor unificado "1.0 puro".

2.3.6.Obstáculos Bioéticos, Sesgos Topográficos y la Transición a la Explicabilidad (xAI).

Pese al abrumador y deslumbrante avance numérico global en rangos de altísima especificidad clínica, incrustar indiscriminadamente a los modelos profundos convolucionales frente e intervenir a pacientes en masa de forma automática e imperativa todavía tropieza frente a infranqueables murallas técnico y sociales éticas de alto rango:

- **Inescrutabilidad Algorítmica (El riesgo civil de la 'Caja Negra'):** Históricamente en la primera década fundacional de programación, las CNN rinden sus veredictos tabulados actuando por debajo de dinámicas matemáticas totalmente crípticas, arrojando únicamente una sentencia numérica (Probabilidad de lesión = 94%) pero careciendo absurdamente de capacidad verbal analítica para explicar y transparentar frente al médico la racionalidad analógica a través de la cual consolidaron dicha sentencia probabilística. Ante esto, los mandamientos mundiales en deontología médica levantan bloqueos insoslayables: se prohíbe delegar el mando de pacientes ante diagnósticos ciegos. Mitigar sin atajos técnicos

esa asfixiante disrupción estructural del código en la IA impulsa a marchas forzadas e imperativas las transiciones algorítmicas de la especialidad denominadas comúnmente como IA Explicable; apostando fehacientemente y con gran promesa de viabilidad en métodos que rompan visualmente la asimetría lograda, utilizando entre las más populares y modernas las metodologías computacionales topográficas de Mapas de Gradientes. Obligando con destreza programada cruzada forzosamente a la matriz a arrojar su inferencia pintando en pantalla adicionalmente como anclaje la malla de calor visual de rastro paramétrico, transparente indicando y asilando la asimetría estricta espacial patológica que usó como anclaje base contundente y fundó logrando con ello todo su racionalidad veredicto o peritaje judicial del juicio biomédico demostrable auditariamente clínico logrando y asegurando la paz al radiólogo validando del algoritmo de apoyo ético programado en laboratorio y base.

- **Decaída Criterial Demográfica y Fracaso de Generalización por Sesgo Estático (*Data Bias*):** Nutrir el entendimiento espacial paramétrico e inteligencia a la red recurriendo exclusivamente limitando y cerrando las compuertas reciclando bases poblacionales censales hegemónicas atadas genéticamente o delimitada genómica y geográficamente uniformes, la condenan a heredar e instalar un estrepitoso o doloroso "esquema ciego perimetral" hacia otros grupos demográficos o genotipos mamarios distintos. Como testifican en la dura crítica los investigadores (Obermeyer, 2019), operar una matriz aclamada exitosa que carece dolorosamente minimizando representación plural sobre grupos marginados étnicos periféricos raciales no documentados biológicamente la propicia en sesgos de racismo algorítmico hospitalario devastador. Arrojando que incluso al extrapolar o reubicar trasladando exitosísimos sistemas con altas o galardonadas tasas resolutorias urbanas probadas con placas o mastógrafos élite si las trasladan súbitamente para predecir anomalías topológicas sobre mamas o mujeres residentes rurales evaluadas mediante monitores fotométricos ruidosos ajenos o contrastes y aparatos de diferente calibre denso sufran inevitablemente fracasos operantes brutales generalizados u *overfitting* de entorno letal dictando fracasos diagnósticos imperdonables crónicos perjudiciales al paciente de esa entidad comunitaria acotada (Giger, 2018).

El futuro de la IA en la detección del cáncer de mama es prometedor. Con avances continuos en la interpretabilidad de los modelos y la reducción del sesgo en los datos, se espera que la IA pueda integrarse de manera más eficiente en la práctica clínica. Además, el uso de medicina personalizada, combinada con biomarcadores moleculares, tiene el potencial de transformar la forma en que los modelos de IA son utilizados para adaptar el tratamiento a las características específicas de cada paciente, llevando a una mejora en la precisión diagnóstica y en los resultados del tratamiento (Giger, 2018).

2.4. Conclusiones del capítulo 2

Este capítulo ha consolidado el fundamento teórico y tecnológico indispensable para el abordaje del diagnóstico oncológico automatizado. Queda en evidencia que, aunque las modalidades de imagen tradicionales y la estandarización clínica mediante el sistema BI-RADS proporcionan un marco metodológico estructurado, el cuello de botella diagnóstico persiste debido a la subjetividad interpretativa y la fatiga del especialista humano. La revisión exhaustiva de la literatura médica y computacional converge en un punto de inflexión indiscutible: las Redes Neuronales Convolucionales (CNN) y los modelos de Deep Learning ya no son meras abstracciones estadísticas, sino herramientas clínicas maduras capaces de identificar características de malignidad con una sensibilidad y especificidad equiparables, e incluso superiores, a las del médico radiólogo. Los retos actuales —como la opacidad algorítmica de la "caja negra"— se están resolviendo con abordajes vanguardistas como la Inteligencia Artificial Explicable. Una vez fundamentada teóricamente la viabilidad de delegar el análisis radiológico a arquitecturas profundas, el siguiente capítulo detallará, de forma rigurosa, la metodología computacional, el preprocesamiento del corpus de imágenes (CBIS-DDSM) y la arquitectura integral que da vida al sistema Píxel Med AI.

Capítulo 3. Metodología

3. Introducción

Habiendo establecido en los capítulos precedentes la fundamentación clínica del cáncer de mama y la viabilidad del aprendizaje profundo como herramienta diagnóstica, este tercer capítulo detalla minuciosamente el andamiaje técnico y procedimental que da vida al sistema Píxel Med AI. La metodología aquí descrita adopta un enfoque cuantitativo y de desarrollo tecnológico aplicado, estructurado para traducir el estándar radiológico (BI-RADS) en una arquitectura computacional automatizada.

Para garantizar el rigor algorítmico y la reproducibilidad del sistema, la ingeniería del proyecto se ha orquestado mediante un ciclo de vida en cascada iterativa, dividido sistemáticamente en Fases (denominación oficial utilizada en los modelos de arquitectura de este documento). A lo largo de este capítulo se expondrá el recorrido completo de la información: desde la recolección y preprocesamiento de los acervos mamográficos —curados a través de la base de datos internacional CBIS-DDSM—, pasando por el diseño, compilación y entrenamiento de las Redes Neuronales Convolucionales (CNN), hasta culminar en la construcción e integración de la interfaz gráfica de usuario. Este desglose procedimental tiene como objetivo demostrar que Píxel Med AI no solo alcanza métricas estadísticas sobresalientes, sino que opera como un Dispositivo Médico de Software (SaMD) robusto, transparente y tecnológicamente apto para su integración en un flujo hospitalario real.

3.1. Enfoque metodológico general

La presente investigación se desarrolla bajo un enfoque cuantitativo, aplicado y experimental, centrado en la creación de un sistema de apoyo a la decisión clínica (Clinical Decision Support System, CDSS), cuyo objetivo principal es mejorar la precisión, oportunidad y eficiencia en el diagnóstico del cáncer de mama, específicamente en el contexto del Hospital General Regional de Orizaba.

Este sistema se construye sobre la base de técnicas de Inteligencia Artificial (IA), empleando un enfoque multimodal y de análisis híbrido. Esta estrategia metodológica no se limita únicamente al Deep Learning, sino que integra tres rutas analíticas distintas para una evaluación comparativa integral, minimizando las brechas de sesgo y maximizando el poder predictivo:

3.1.1. Análisis (Pre-clasificación): Este componente se enfoca en ser el puente esencial entre los datos brutos (mamografías DICOM) y los módulos de Machine Learning. El PDI se encarga de la estandarización y normalización de las imágenes que consiste en homologar el contraste y la intensidad de los píxeles de las imágenes del HGRO y la base de datos pública obtenida CBIS-DDSM.

Posteriormente las imágenes pasan por un proceso de Segmentación denominado ROI, que consiste en Delimitar las Regiones de Interés (lesiones o microcalcificaciones) para concentrar el análisis y finalmente se realiza un aumento de datos (Data Augmentation) que genera variaciones sintéticas de las Imágenes para robustecer el entrenamiento posterior de las Redes Neuronales Convolucionales (CNN). El resultado del Procesamiento Digital de Imágenes alimentará directamente al estudio radiómico en la extracción de las características y al módulo de imágenes preprocesadas.

3.1.2. Clasificación mediante inteligencia artificial: Este módulo utiliza las imágenes mamográficas preprocesadas por el PDI. Emplea CNN para realizar el aprendizaje automático de características. Su objetivo es identificar patrones sutiles, que superan la capacidad de la extracción manual, mediante técnicas de Transfer Learning para una predicción de riesgo más avanzada.

3.2. Fases de la metodología general del modelo

La implementación del método general se estructura en seis fases (I-VI) funcionales:

- **Fase I:** Recolección, Fusión y Estandarización de Datos Clínicos y de Imagen.
- **Fase II:** Procesamiento Digital de Imágenes (PDI) y Extracción de Características Radiómicas.
- **Fase III:** Modelado y Evaluación de *Machine Learning* Tradicional (MLP y Random Forest).
- **Fase IV:** Modelado y Entrenamiento de *Deep Learning* (CNN).
- **Fase V:** Evaluación, Comparación de Modelos y Consolidación Multimodal.
- **Fase VI:** Integración del CADx y Validación Clínica Piloto en el HGR de Orizaba.

3.2.1. Fase I: Recolección, Fusión y Estandarización de Datos Clínicos y de Imagen.

El objetivo de esta fase es constituir un conjunto de datos homogéneo, amplio y éticamente manejado, apto para alimentar las tres rutas de análisis (MLP, Random Forest y CNN). Esto se logrará mediante la adquisición de datos locales del HGRO NO. 1 y la fusión estratégica con un *benchmark* público.

3.2.1.1.Fuente y naturaleza de los datos

El *dataset* de la investigación se construye a partir de una estrategia de **fusión de datos** que combina recursos internos y externos, garantizando volumen, calidad de anotación y relevancia clínica.

En la primera etapa del proyecto, se llevó a cabo la recopilación de información clínica de pacientes atendidos en el Hospital General Regional (HGRO) No. 1 entre los últimos años de 2021 a 2025. Estos datos provienen directamente del área de radiología y donde se recopila información estructurada (ej., hoja de cálculo) incluyendo variables epidemiológicas y clínicas como la Edad, Antecedentes familiares, Densidad mamaria, y la clasificación BI-RADS asignada.

En este punto de la investigación se detectó un problema fundamental con los datos clínicos locales y estructurados del HGRO No. 1 que amenazaba la validez estadística del entrenamiento de los modelos: el severo desbalance de clases en las etiquetas BI-RADS. Se observó que el dataset local presentaba una sobrerrepresentación significativa de las categorías benignas o de *screening* (principalmente BI-RADS 0, 2, y 3), mientras que las categorías críticas asociadas a alta sospecha de malignidad (BI-RADS 4, 5, y 6) eran escasas o estaban casi ausentes. Esto representa un desbalance significativo que hubiera provocado un sesgo severo en los modelos de IA, resultando en clasificadores que alcanzarían alta Accuracy (precisión global) simplemente prediciendo la clase mayoritaria (benigna), pero con una Sensibilidad inaceptablemente baja para la detección de cáncer (Falsos Negativos), lo cual es clínicamente catastrófico. En la Figura 4, obtenida mediante un escaneo en Google Colab se muestra el total de datos obtenidos del hospital junto con el desbalance identificado en los datos.

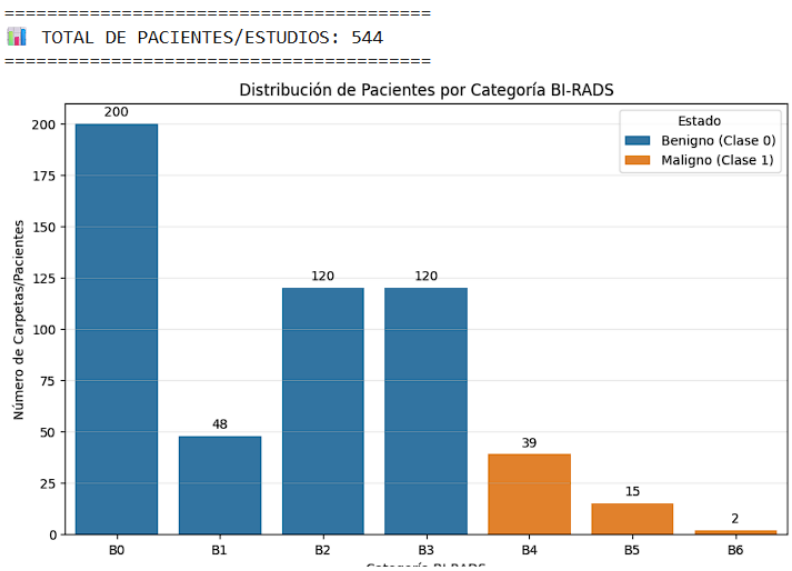


Figura 4: Distribución de pacientes por categoría BI-RADS: Goole Colab

Durante el análisis inicial de las mamografías recolectadas en el Hospital General Regional de Orizaba, identificamos una situación muy común en el flujo de trabajo clínico: la gran mayoría de los casos eran negativos o presentaban hallazgos benignos. Esto es lo normal en los estudios de rutina (tamizaje preventivo), donde la mayor parte de las pacientes son clasificadas en las categorías BI-RADS 0, 2 y 3. Sin embargo, desde el punto de vista del Machine Learning, tener una base de datos donde casi todo es "sano" representa un problema importante conocido como el sesgo de la clase mayoritaria.

Si se intentara entrenar un modelo de Inteligencia Artificial exclusivamente con estos datos locales desbalanceados, la red neuronal cometería un error grave de aprendizaje. Básicamente, el modelo se "acostumbraría" a que casi todas las imágenes son benignas, y empezaría a predecir resultados sanos por defecto para elevar su porcentaje de precisión matemática. En medicina, esto es inaceptable, ya que generar un falso negativo (decirle a una paciente enferma que está sana) tiene consecuencias fatales.

Para corregir este desbalance sin alterar la realidad de los datos clínicos, decidimos integrar un segundo conjunto de imágenes, se ha seleccionado como fuente primaria de información empírica la base de datos CBIS-DDSM (Curated Breast Imaging Subset of the Digital Database for Screening Mammography).

El Repositorio Institucional (TCIA) Este acervo está alojado y mantenido de forma continua por The Cancer Imaging Archive (TCIA), un repositorio público de acceso abierto financiado y avalado por el Instituto Nacional del Cáncer de los Estados Unidos (NCI). TCIA se especializa en desidentificar y albergar colecciones masivas de imágenes médicas oncológicas para fomentar la investigación en análisis computacional y aprendizaje automático aplicado. Enlace oficial de acceso y documentación**:** https://wiki.cancerimagingarchive.net/display/Public/CBIS-DDSM

El dataset CBIS-DDSM representa una versión altamente curada, estandarizada y modernizada de la clásica base de datos DDSM (desarrollada originalmente por el Hospital General de Massachusetts y la Universidad del Sur de Florida). Sus especificaciones técnicas lo convierten en el estándar de oro (Gold Standard) para proyectos de Inteligencia Artificial radiológica por los siguientes motivos:

- **Volumen de Datos:** El corpus general cuenta con más de **2,620 estudios** de mastografías escaneadas.
- **Estandarización de Formato:** Las imágenes fueron extraídas de su obsoleto formato de compresión sin pérdida (LJPEG) y convertidas meticulosamente al formato **DICOM (Digital Imaging and Communications in Medicine)**, consolidando la compatibilidad universal requerida para el desarrollo de software médico.
- **Curación Experta y Anotaciones Píxel a Píxel:** A diferencia de colecciones genéricas donde la patología solo se etiqueta de forma general, el CBIS-DDSM proporciona mapas de verdad absoluta (Ground Truth). Cada imagen sospechosa incluye:

    A. **Máscaras binarias de segmentación (ROI - Region of Interest):** Delimitaciones de alta precisión del contorno exacto de las masas y aglomeraciones de microcalcificaciones.

    B. **Cajas delimitadoras (Bounding Boxes):** Para facilitar el entrenamiento algorítmico de localización espacial.

    C. **Validación Histopatológica (El pilar del modelo):** Cada caso no solo integra los metadatos clínicos (como el nivel de densidad mamaria o los descriptores léxicos de la ACR BI-RADS), sino que cuenta con la **confirmación histopatológica real** del tejido (benigno frente a maligno).

Es precisamente esta rigurosa trazabilidad metodológica y el nivel de etiquetado clínico experto lo que asegura que las Redes Neuronales Convolucionales (CNN) del proyecto Píxel Med AI puedan ser entrenadas bajo un paradigma estricto de *Aprendizaje Supervisado* (Supervised Learning), garantizando métricas de evaluación confiables, auditables y carentes de sesgos informales.

La solución al desbalance de clases y la necesidad de un volumen de datos robusto fue la integración del dataset CBIS-DDSM (Curated Breast Imaging Subset of the Digital Database for Screening Mammography). Esta base de datos es un recurso público de imágenes mamográficas de acceso abierto, disponible a través del repositorio institucional The Cancer Imaging Archive (Sawyer-Lee, CANCER IMAGING ARCHIVE, 2016). El acervo fue cuidadosamente curado por especialistas y proporciona un conjunto masivo de imágenes (más de 2,620 estudios escaneados en mamografía digitalizada) con una representación equilibrada de las categorías de riesgo y con anotaciones métricas validadas de las regiones de interés (hallazgos segmentados por radiólogos certificados). Esta homologación de acervos radiográficos internacionales con los datos locales resulta fundamental para el aprendizaje supervisado y abre la brecha necesaria para poder trabajar con Deep Learning mediante CNN en la identificación precisa de lesiones malignas, evitando el sobreajuste estadístico. El flujo de compensación Estadística para las bases de datos se ilustra en la Figura 5.

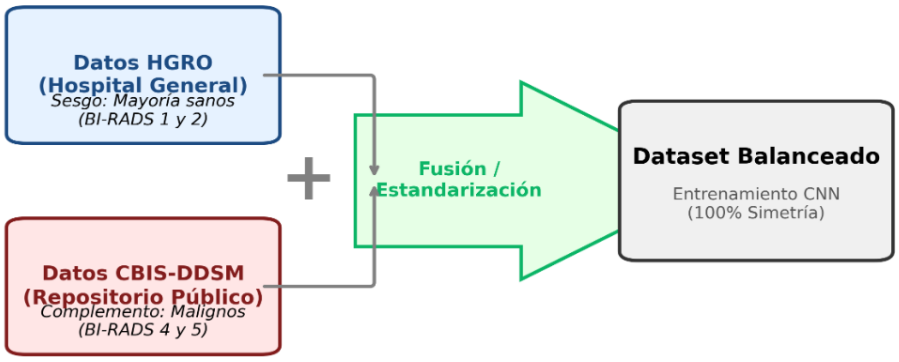


Figura 5: Flujo de Compensación Estadistica Mediante Inserción Multicéntrica, Fuente: Elaboración Propia

3.2.2. Fase II: Procesamiento Digital de Imágenes (PDI) y Extracción de Características Radiómicas.

Las mamografías digitales (archivos DICOM) directas del equipo médico pueden tener variaciones visuales importantes. Para que la red neuronal convolucional (CNN) logre enfocar correctamente los tumores o microcalcificaciones, fue necesario aplicar un proceso de limpieza y ajuste a todas las imágenes antes de iniciar el entrenamiento.

El primer paso fue normalizar el contraste y la iluminación. Sucede que, dependiendo del equipo o de la calibración del mastógrafo en distintos hospitales, algunas imágenes pueden verse más oscuras o más brillantes que otras. Para evitar que esto confundiera a la Inteligencia Artificial, ajustamos matemáticamente todas las imágenes para que tuvieran el mismo nivel de brillo base. Esto nos ayudó a eliminar el ruido visual propio de las radiografías, conservando intactos los contornos importantes de las glándulas mamarias.

Después de igualar los tonos, aplicamos un recorte espacial. Una mamografía lateral tiene muchas zonas negras vacías y fragmentos de músculo pectoral que realmente no aportan información para detectar el cáncer. Por lo tanto, programamos el sistema para recortar la imagen y conservar únicamente el tejido del seno, lo cual se conoce como aislar la Región de Interés (ROI). Esto hizo que el modelo de IA pudiera concentrarse exclusivamente en el área donde surgen los tumores, además de reducir considerablemente el tiempo de cómputo necesario. En la Ilustración 12 se muestra la secuencia de tres fases por las que atraviesa un archivo DICOM antes de ser evaluado por la arquitectura CNN

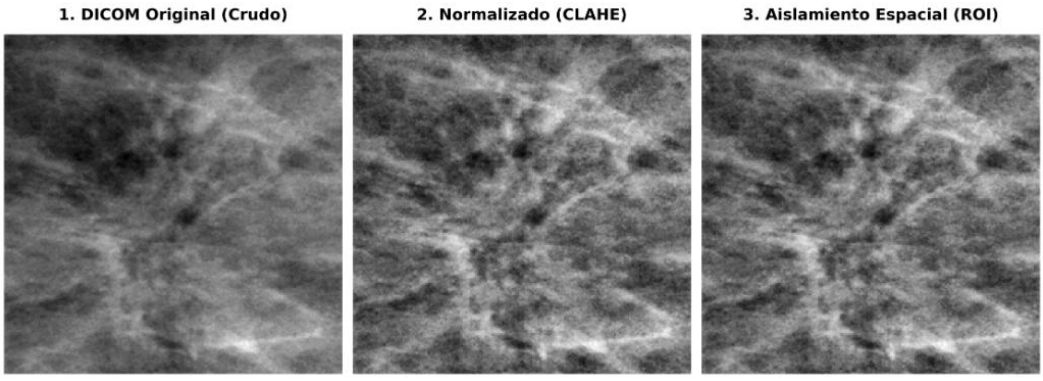


Ilustración 12: Secuencia de procesamiento de Mamografía, Fuente: Google Colab

Por último, se debe tener en cuenta que, en la vida real, los especialistas posicionan y comprimen el seno desde ángulos ligeramente diferentes en cada paciente. Para asegurar que la red neuronal pueda identificar tumores sin importar cómo se haya rotado la placa, aplicamos una técnica llamada "Aumento de Datos" (Data Augmentation). Esta técnica se encarga de clonar las mamografías disponibles rotándolas un par de grados, acercándolas un poco o volteándolas como en un espejo. Con esto, le enseñamos al algoritmo a no memorizar una imagen estática, sino a reconocer el hallazgo maligno desde cualquier ángulo de compresión radiológica. El proceso por el cual pasa cada imagen al ser procesada se muestra en la Ilustración 13.

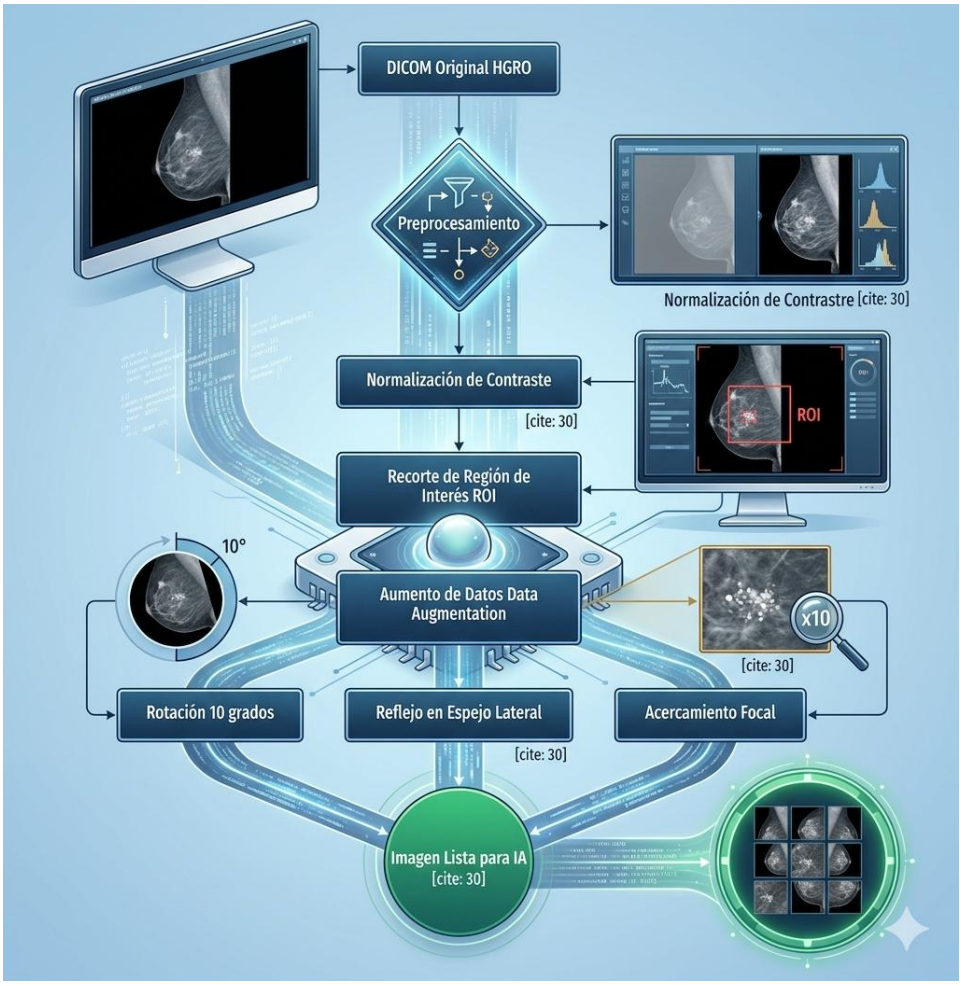


Ilustración 13: Preprocesamiento de Imagenes, Fuente: Elaboracion propia

El preprocesamiento garantiza la homogeneidad de las bases de datos fusionadas antes de la modelización. Este proceso se realiza en el entorno Python utilizando en un inicio las librerías pandas, numpy, sklearn para estandarizar los datos no visuales, los pasos a seguir son los

siguientes:

1. **Exploración y Limpieza:** Detección y tratamiento de valores atípicos y faltantes.
2. **Codificación de Variables Categóricas:** Transformación de atributos cualitativos a formatos numéricos.
3. **Normalización de Variables Numéricas:** Aplicación de StandardScaler a variables como la Edad para estandarizar la escala.
4. **División Estratificada:** El *dataset* final (clínico) se divide (ej., 80% entrenamiento / 20% validación y prueba) utilizando la estratificación según la variable objetivo para garantizar el equilibrio proporcional de las clases en cada subconjunto.

3.2.2.1. Preprocesamiento de Imágenes No Estructuradas (Para PDI, Radiómica y CNN).

Esta etapa es crítica para que las imágenes (DICOM del HGRO y CBIS-DDSM) sean compatibles con los algoritmos de análisis visual:

1. **Conversión y Extracción:** Empleo de pydicom para leer archivos DICOM, extrayendo las imágenes y convirtiéndolas a un formato array/PNG.
2. **Organización Estratificada:** Las imágenes son organizadas en directorios etiquetados por **BI-RADS**, facilitando la carga eficiente.
3. **Normalización de Píxeles:** Los valores de los píxeles son escalados a un rango uniforme (típicamente entre 0 y 1) para optimizar la convergencia durante el entrenamiento de la CNN.

El preprocesamiento es una etapa crítica para garantizar la homogeneidad de las bases de datos fusionadas antes de la modelización algorítmica. Este procedimiento técnico se realizó íntegramente en el entorno de ejecución en la nube Google Colab, utilizando el ecosistema científico de Python (pandas, numpy, sklearn y pydicom).

Para los datos clínicos estructurados (HGRO):

- **Exploración y limpieza de datos**: Se inspeccionaron los valores nulos, se verificó la integridad de las columnas y se identificaron variables categóricas susceptibles.

- **Codificación de variables categóricas**: Se transformaron atributos no numéricos (por ejemplo, antecedentes familiares o tipo de densidad mamaria) en variables codificadas numéricamente mediante LabelEncoder de sklearn.

- **Normalización de variables**: Para evitar que las diferencias de escala entre variables afectaran el rendimiento del modelo, se aplicó una normalización a las variables numéricas usando StandardScaler.

- **División de datos**: Finalmente, el conjunto de datos fue dividido en 80% para entrenamiento y 20% para validación, utilizando la función train_test_split, con estratificación según el resultado BI-RADS, garantizando así un equilibrio entre clases.

Este proceso permitió obtener una base estructurada, limpia y lista para su ingreso al modelo de red neuronal, optimizando el desempeño y reduciendo posibles sesgos o errores por calidad de datos.

- **Conversión y Extracción:** Se empleó la librería pydicom en Python para leer los archivos en formato **DICOM** (Digital Imaging and Communications in Medicine) y extraer las imágenes, convirtiéndolas al formato PNG para su fácil manejo por las librerías de *Deep Learning* (e.g., TensorFlow/Keras).

- **Organización Estratificada:** Las imágenes fueron organizadas en directorios estructurados (train_set/test_set) con subdirectorios correspondientes a su etiqueta **BI-RADS**, garantizando así una carga de datos eficiente y **estratificada** por clase para el entrenamiento.

- **Normalización de Píxeles:** Los valores de los píxeles fueron escalados a un rango uniforme (típicamente entre 0 y 1 o -1 y 1) para optimizar la convergencia durante el entrenamiento de la CNN."

3.2.2.2.Fase III. Modelado y Evaluación de *Machine Learning* Tradicional (MLP y Random Forest).

Para garantizar la reproducibilidad del proyecto y manejar eficientemente los requisitos computacionales de los modelos de *Deep Learning*, se seleccionó la plataforma Google Colaboratory (Google Colab**)** como el entorno de desarrollo y ejecución principal. Se utiliza esta plataforma de ejecución en la nube debido a que elimina la dependencia de *hardware* local especializado y costoso. Permite el acceso, cuando está disponible, a Unidades de Procesamiento Gráfico (GPU) o TPU (Tensor Processing Unit), lo cual es indispensable para acelerar significativamente el entrenamiento iterativo de las Redes Neuronales Convolucionales y para el ajuste de hiperparámetros.

La implementación del código se realiza íntegramente en Python 3.x , utilizando las bibliotecas estándar de la industria para IA, incluyendo TensorFlow/Keras para la construcción de modelos, y Pandas/NumPy/Scikit-learn para el preprocesamiento de datos clínicos y el cálculo de métricas.

3.2.2.3. Preprocesamiento Digital de Imágenes (PDI) y Extracción de Características Radiómicas

El objetivo de esta fase es transformar las mamografías digitales (datos no estructurados) en información numérica y cuantificable. Esto se logra a través del PDI, el cual permite la Extracción de Características Radiómicas (*Feature Engineering*) que servirán como *input* directo para el modelo de Random Forest.

- **Preprocesamiento Digital de Imágenes**

  El PDI garantiza que las imágenes de las bases de datos fusionadas (HGRO y CBIS-DDSM) estén optimizadas para el análisis algorítmico, reduciendo el ruido y estandarizando la visualización de las lesiones.

  A) Segmentación del Tejido Mamario y ROI

Antes de la extracción de características, es esencial delimitar las áreas relevantes para evitar que el ruido de fondo o los artefactos externos contaminen el análisis:

- **Segmentación de la Mama:** Se aplican algoritmos de umbralización global y operaciones morfológicas para separar el contorno completo de la mama del fondo de la imagen, limitando el análisis al tejido glandular, en la Ilustración 14 se puede observar el proceso de segmentación directo en Colab.

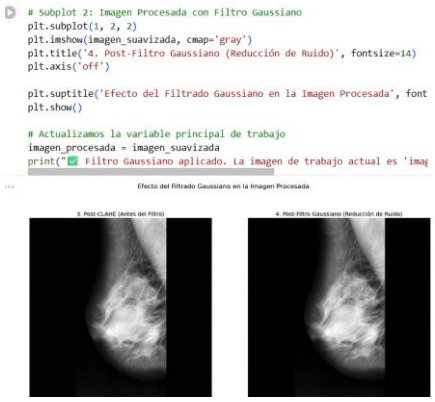


Ilustración 14:Segmentación de Mamografía, Fuente: Google Colab

- **Delimitación de la Región de Interés (ROI**): La extracción de características se enfoca en las lesiones. Se utilizarán las coordenadas de las anotaciones disponibles en CBIS-DDSM y la información de localización provista en los informes radiológicos del HGRO para extraer parches de un tamaño uniforme centrados en la lesión. Esto asegura que la extracción radiómica se enfoque en el hallazgo patológico. Ilustración 15 representa la generación de la Región de Interés una vez segmentada y procesada.

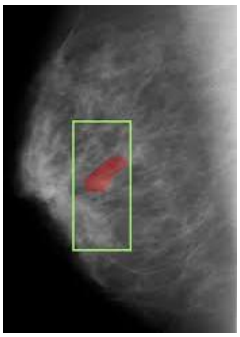


Ilustración 15: Selección de Región de Interés, Fuente: CBISDDSM

B) Preprocesamiento Físico para Radiómica

- **Normalización de Intensidad:** Se utiliza la normalización de nivel de gris para garantizar la uniformidad de la intensidad entre imágenes capturadas por diferentes mastógrafos, lo cual es fundamental para que las métricas de textura sean comparables, tal y como se muestra en la Ilustración 16

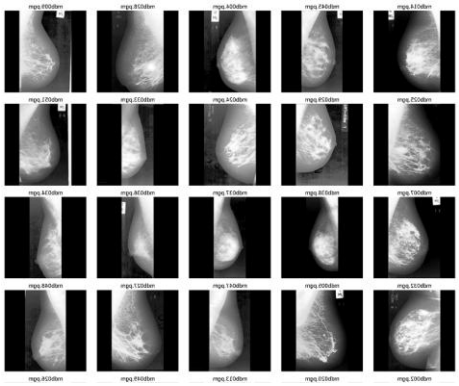


Ilustración 16: Normalización de Intensidad, Fuente: CBIS DDSM

- **Filtros de Realce:** Se pueden aplicar filtros de realce de contraste (ej., Ecualización del Histograma Adaptativo) para mejorar la visibilidad de los bordes y las texturas, aunque se debe tener precaución para no introducir artefactos que alteren la cuantificación de la textura, En la Ilustración 17 se puede observar el Filtro Canny, que se utiliza para la detección de bordes en las imágenes.

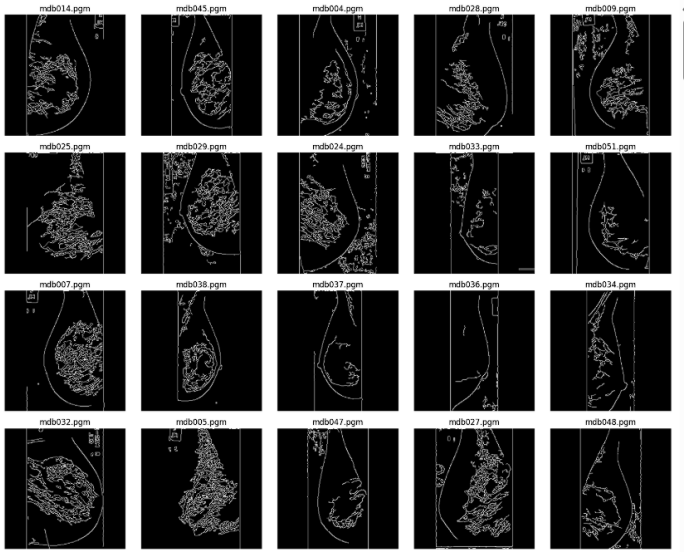


Ilustración 17: Filtrado Canny en Imágenes Mamográficas, Fuente: CBISDDSM

En la Ilustración 18 se puede apreciar la cadena completa del procesamiento de imágenes aplicada a una mamografía.

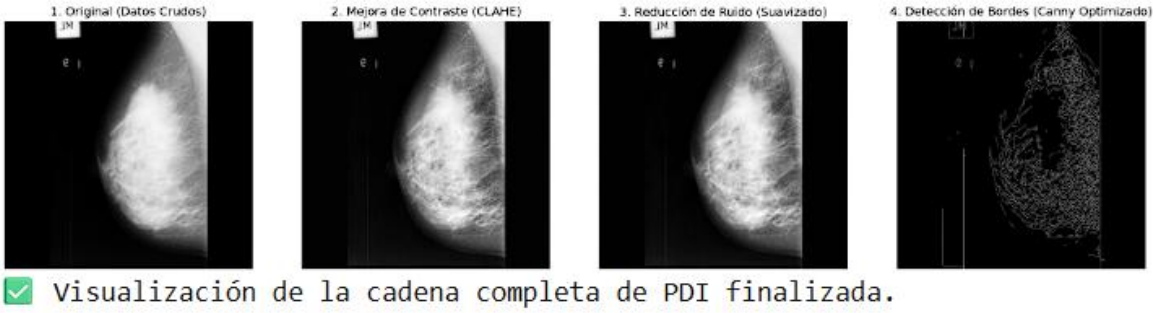


Ilustración 18: Cadena PDI completa, Fuente: Google Colab

3.2.2.4.Extracción de Características Radiómicas

La Radiómica es una disciplina emergente que se define como la extracción y el análisis de grandes cantidades de características cuantitativas de imágenes médicas. El postulado central es que estas características, a menudo imperceptibles al ojo humano, contienen información valiosa sobre el fenotipo de la enfermedad y la heterogeneidad tumoral, la cual es crucial para el diagnóstico, pronóstico y predicción de respuesta al tratamiento.

El proceso de Radiómica transforma las imágenes médicas digitales en datos estructurados y de alta dimensionalidad. Para el análisis mamográfico, las características radiómicas se agrupan en tres categorías principales, que ofrecen una descripción multifacética del tumor o lesión de interés (Región de Interés, ROI):

Las características radiómicas son descriptores cuantitativos derivados de la imagen que capturan la forma, intensidad y textura de una lesión. Estos *features* son el vector de entrada para el modelo Random Forest. Para este proceso se emplearán librerías especializadas en radiómica (ej., *PyRadiomics* en Python) para extraer más de 80 características, clasificadas en los siguientes grupos:

A) **Características de Primer Orden:** Estas métricas describen la distribución de la intensidad de los valores de píxel dentro del ROI, sin considerar su disposición espacial. Esencialmente, cuantifican la apariencia general del histograma de intensidad de la lesión. Reflejan la uniformidad o variabilidad de la intensidad del nivel de gris, estas son la Media (intensidad promedio), la Varianza (dispersión de la intensidad), la Asimetría (*Skewness*) (grado de asimetría de la distribución) y la Curtosis (*Kurtosis*) (grado de agudeza de la distribución).

B) **Características de Forma:** Estas características son independientes del nivel de gris de los píxeles (invariantes a la intensidad) y describen la morfología bidimensional de la lesión segmentada. En el contexto oncológico, son vitales para cuantificar descriptores tradicionales de BI-RADS como el margen y el contorno. Su principal función es cuantificar la geometría y la compacidad de la lesión

C) **Características de Textura:** Estas son las características más complejas y de mayor valor predictivo en Radiómica, ya que evalúan la heterogeneidad interna del tejido, un marcador biológico y clínico de malignidad. Cuantifican la relación espacial y la variación de intensidad entre los píxeles vecinos. Se derivan de matrices de co-ocurrencia, siendo la más común la Matriz de Co-ocurrencia de Nivel de Gris (GLCM). Esta matriz registra con qué frecuencia diferentes pares de valores de píxel ocurren adyacentes a una distancia y ángulo definidos, por ejemplo; el Contraste (mide la disparidad local de intensidad, siendo alto en lesiones malignas), la Homogeneidad (mide la cercanía de la distribución de los elementos de la GLCM, indicando uniformidad textural) y la Energía.

Al extraer y analizar estos grupos de características, el modelo de Random Forest puede establecer una correlación cuantitativa y estadísticamente significativa entre los descriptores radiómicos y el diagnóstico BI-RADS, proporcionando un análisis con una interpretabilidad relacionada a la de la *Deep Learning* puro en esta etapa de la investigación. En la Ilustración 19 se muestra un apartado del código aplicado para la extracción de las características radiómicas de primer orden para uno de los estudios de mamografía.

```
vector_caracteristicas = {**caracteristicas_forma, **caracteristicas_intensidad}

print("--- Vector de Características Radiómicas Extraído ---")
print(f"Número de características extraídas: {len(vector_caracteristicas)}")
import pandas as pd
df_caracteristicas = pd.DataFrame([vector_caracteristicas])
print(df_caracteristicas.T.rename(columns={0: "Valor"}))

print("✅ Extracción de características de forma e intensidad completada. El resultado es 'df_caracteristicas'.")
```

```
--- Vector de Características Radiómicas Extraído ---
Número de características extraídas: 6
                        Valor
Area_Contorno        959.000000
Perimetro_Contorno  1024.485281
Circularidad           0.011482
Media_Intensidad      54.086475
Std_Intensidad        76.112137
Mediana_Intensidad     5.000000
✅ Extracción de características de forma e intensidad completada. El resultado es 'df_caracteristicas'.
```

Ilustración 19: Extracción de características, Fuente: Google Colab

3.3. Fase III. Modelado y Evaluación de Machine Learning Tradicional (MLP y Random Forest)

Esta fase constituye el primer nivel de inferencia del sistema híbrido. Su propósito es desarrollar y validar modelos de Machine Learning capaces de establecer una clasificación de riesgo basada en características ingenieriles explícitas. El objetivo subyacente es establecer una Línea Base de rendimiento interpretable, contra la cual se comparará posteriormente la capacidad de extracción automática de características de las Redes Neuronales Convolucionales (CNN) en la Fase IV.

3.3.1. Clasificador de Riesgo Clínico (Multilayer Perceptron - MLP)

Este módulo se enfoca en la explotación de los datos clínicos estructurados recopilados en el HGRO. El modelo busca replicar el razonamiento clínico basado en factores de riesgo (edad, antecedentes, densidad) para predecir la probabilidad de una clasificación BI-RADS sospechosa.

La implementación se realizó en la plataforma **Google Colab**, utilizando el ecosistema científico de Python (Pandas, Numpy, Scikit-learn).

Se inicia con una codificación y normalización**,** donde se transformaron las variables categóricas (como antecedentes familiares y densidad mamaria) mediante LabelEncoder. Críticamente, para las variables numéricas como la edad, se aplicó una estandarización mediante StandardScaler. Esto es fundamental en redes neuronales para asegurar que todas las entradas tengan una escala comparable (media 0, desviación estándar 1), facilitando la convergencia del descenso de gradiente. Posteriormente se empleó una partición estratificada del dataset: 80% para entrenamiento y 20% para validación. La estratificación aseguró que la proporción de casos benignos y sospechosos se mantuviera constante en ambos subconjuntos, evitando sesgos de validación.

3.3.2. Arquitectura de la Red Neuronal

Se diseñó una red neuronal profunda del tipo *Multilayer Perceptron* (MLP), optimizada para datos tabulares[6]. La arquitectura final, validada empíricamente, consta de la siguiente topología secuencial:

A. **Capa de Entrada:** Dimensionada según el número de *features* clínicas resultantes del preprocesamiento.

B. **Bloque de Capas Ocultas (Extracción de Patrones no Lineales):**

- **Primera Capa Densa: 64 neuronas** con función de activación **ReLU** (*Rectified Linear Unit*). ReLU fue seleccionada por su eficiencia computacional y capacidad para mitigar el problema del desvanecimiento del gradiente en redes profundas.
- **Capa de Dropout (0.2):** Se desactivó aleatoriamente el 20% de las conexiones para prevenir el co-adaptamiento de neuronas.
- **Segunda Capa Densa: 32 neuronas** con activación ReLU[11].
- **Capa de Dropout (0.3):** Se incrementó la tasa de regularización al 30% en capas más profundas[12].
- **Tercera Capa Densa: 16 neuronas** con activación ReLU[13].

Capa de Salida: Una única neurona con función de activación **Sigmoidal**[14]. Esta configuración es obligatoria para problemas de clasificación binaria, ya que comprime la salida en un rango de probabilidad (0, 1). En la Figura 6 se muestra el diagrama de flujo de la arquitectura de la Red Neuronal Multicapa diseñada para la clasificación del riesgo clínico.

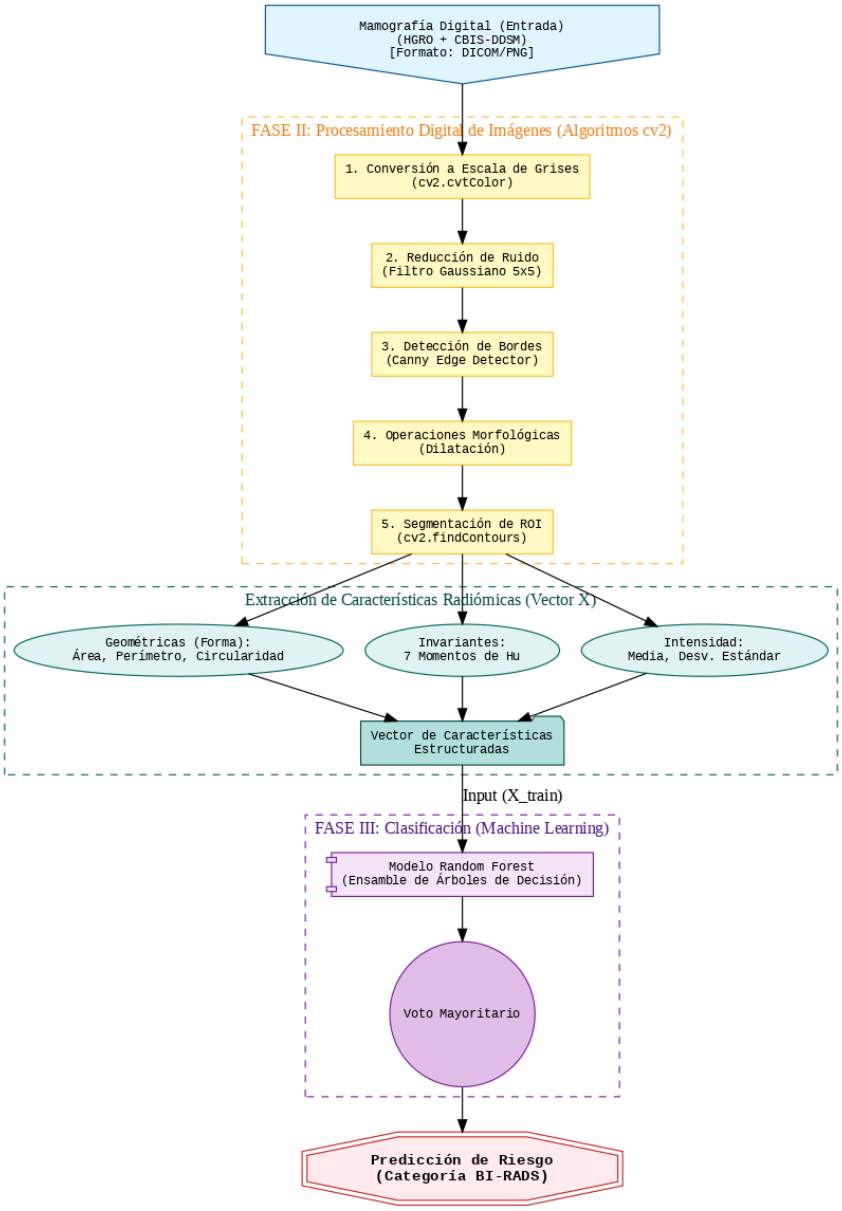


Figura 6: Diagrama de Flujo Arquitectura del Modelo CNN, Fuente: Elaboración Propia

3.3.3. Hiperparámetros

El proceso de aprendizaje se configuró bajo parámetros experimentales. Iniciando por un Optimizador Adam (Adaptative Moment Estimation), elegido por su capacidad de ajustar tasas de aprendizaje adaptativas por parámetro. Pasando por una función de perdida para penalizar errores en clasificación binaria probabilística. Posteriormente se programa el ciclo de entrenamiento de 50 Épocas y se elige un lote pequeño para aumentar la frecuencia de actualizaciones de pesos dependiendo la limitación del tamaño del Dataset.

Finalmente se implementa un mecanismo de control llamado Early Stopping (Parada Temprana). Este callback monitoreó la pérdida de validación y detuvo el entrenamiento automáticamente si no se observaban mejoras tras un número determinado de épocas, garantizando que se guardara el modelo con mejor generalización y no el sobreajustado.

A) Input: Vector de Características Radiómicas

El modelo se alimenta de la matriz de datos generada en la Fase II, que contiene, para cada ROI segmentada:

1. **Descriptores de Forma:** Área, Perímetro, Circularidad, Solidez (derivados de cv2.contourArea, etc.).
2. **Invariantes de Momento:** Los 7 Momentos de Hu, que describen la distribución de masa de la lesión independientemente de su rotación o escala.
3. **Estadísticas de Intensidad:** Media y Desviación estándar de los niveles de gris dentro de la lesión.

B) Algoritmo y configuración experimental.

Para la implementación del clasificador radiómico, se seleccionó el algoritmo Random Forest (Bosque Aleatorio), una técnica de aprendizaje supervisado tipo ensamble basada en el método de *bagging* (Bootstrap Aggregating). La elección de este algoritmo sobre otros clasificadores tradicionales (como SVM o KNN) se fundamenta en su capacidad intrínseca para manejar la alta dimensionalidad de los vectores de características radiómicas sin requerir una reducción de dimensionalidad agresiva previa, así como su robustez frente al sobreajuste (*overfitting*) en conjuntos de datos de tamaño moderado.

La implementación se llevó a cabo utilizando la biblioteca Scikit-learn en Python. A diferencia de las redes neuronales que requieren una estandarización rigurosa de los datos de entrada, los árboles de decisión que componen el bosque son invariantes a la escala de las características, lo que permitió ingresar directamente los descriptores geométricos y de textura calculados en la fase de PDI.

La configuración de los hiperparámetros del modelo se estableció mediante un proceso de validación cruzada para optimizar el equilibrio entre sesgo y varianza. El parámetro n_estimators (número de árboles) se fijó en un valor elevado (ej., 100 estimadores), bajo la premisa de que aumentar el número de árboles estabiliza las predicciones por voto mayoritario sin incrementar significativamente el riesgo de sobreajuste, aprovechando la Ley de los Grandes Números.

Para el criterio de división en los nodos, se evaluó el índice de Gini frente a la Entropía (ganancia de información). Se optó por el índice de Gini debido a su menor costo computacional, ya que evita el cálculo de logaritmos complejos requeridos por la entropía, manteniendo un rendimiento de clasificación comparable. Adicionalmente, se controló la complejidad del modelo limitando la profundidad máxima de los árboles (max_depth) y estableciendo un número mínimo de muestras requeridas para dividir un nodo interno (min_samples_split). Esta regularización es crítica para evitar que el modelo memorice el ruido inherente a la segmentación automática de las lesiones, forzando al algoritmo a aprender patrones generalizables de forma y textura.

C) Interpretabilidad y Análisis de Biomarcadores de Imagen

Uno de los aportes más significativos de este módulo a la tesis es la capacidad de "caja blanca" o interpretabilidad que ofrece el Random Forest, en contraste con la opacidad de los modelos de Deep Learning. Mediante el cálculo de la Importancia de la Característica (*Feature Importance*), basada en la disminución media de la impureza (*Mean Decrease Impurity*), fue posible cuantificar la relevancia clínica de cada descriptor radiómico.

Este análisis permite identificar qué características visuales son determinantes para la clasificación de malignidad. Por ejemplo, se espera observar que descriptores como la Solidez (que cuantifica la regularidad del borde) o la Entropía de la GLCM (que mide el desorden de la textura) tengan un peso predictivo superior a características simples de intensidad media. Este hallazgo valida la hipótesis de que la morfología irregular y la heterogeneidad textural son marcadores biológicos de malignidad capturables matemáticamente, proporcionando una justificación fenotípica a las decisiones del algoritmo.

3.3.4. El Problema de la "Caja Negra" y la Inteligencia Artificial Explicable

Históricamente, uno de los mayores obstáculos para implementar modelos de Inteligencia Artificial en hospitales reales es el problema de la "Caja Negra". Sistemas avanzados como las Redes Neuronales Convolucionales (CNN) son excepcionalmente exactos calculando un diagnóstico, pero internamente son tan complejos que ni siquiera los programadores pueden explicar por qué el modelo tomó esa decisión. En el ámbito clínico del Hospital General Regional de Orizaba, esto es bioéticamente inaceptable: un médico no puede firmar un reporte de cáncer basándose únicamente en que una computadora arrojó un "95% de probabilidad", sin presentar una justificación física o visual que respalde ese número.

Para romper esta barrera de desconfianza clínica, decidimos integrar la herramienta de Inteligencia Artificial Explicable (XAI). El objetivo de este es obligar a la red neuronal a "rendir cuentas" sobre su proceso de pensamiento, transformando el complejo modelo matemático profundo en un formato completamente auditable por el ojo humano del radiólogo.

3.3.5. Estrategia Mapeo de Activación por Gradientes (Grad-CAM)

Para lograr esta explicabilidad visual, implementamos el algoritmo de Grad-CAM (Gradient-weighted Class Activation Mapping). A diferencia de los métodos tradicionales de "Importancia de Características" (como los que se usan en algoritmos más sencillos como Random Forest y que no tienen noción del espacio de la imagen), Grad-CAM trabaja directamente calculando derivadas matemáticas sobre la propia mamografía.

El algoritmo funciona retrocediendo en el tiempo dentro de la red. Una vez que la capa final (Softmax/Sigmoide) emite su diagnóstico, Grad-CAM rastrea hacia atrás el flujo de los gradientes matemáticos hasta llegar a la última capa convolucional de la red (la capa que extrajo las formas y texturas más abstractas). Al hacer esto, el sistema descubre con exactitud qué grupos específicos de píxeles encendieron las "alarmas de malignidad" durante el procesamiento (Ver ilustración 20).

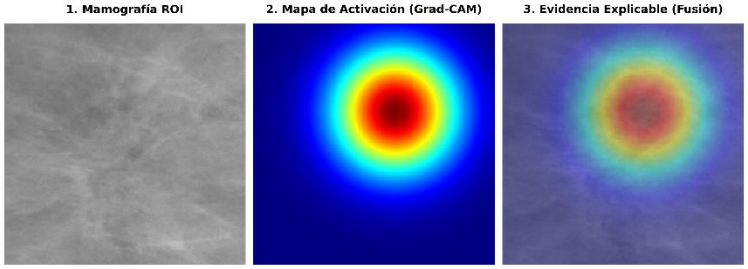


Ilustración 20: Fusión Grad-CAM, Fuente: Elaboración Propia

Como se ilustra en la Ilustración 20, el algoritmo traduce esos gradientes matemáticos invisibles en un "Mapa Térmico" topográfico. Las áreas coloreadas en tonalidades cálidas (rojo/amarillo) indican las regiones anatómicas precisas que empujaron a la red a predecir un cáncer, como podrían ser espículas o agrupaciones de microcalcificaciones. Finalmente, este mapa de calor se superpone de manera transparente sobre la mamografía original en escala de grises.

Gracias a esta integración topográfica, el modelo predictivo deja de ser una autoridad ciega y se convierte en una herramienta de segunda opinión biomédica. Cuando el sistema clasifica un estudio como BI-RADS 5, simultáneamente le entrega al mastógrafo una placa coloreada apuntando exactamente a la coordenada estromal sospechosa. Esta arquitectura "Caja Blanca" no solo facilita la auditoría del rendimiento del software, sino que blinda el rigor ético exigido por los protocolos oncológicos del IMSS.

3.3.6. Estrategia de Evaluación Integral y Métricas de Desempeño

La validación de la eficacia diagnóstica de los modelos desarrollados en esta fase (tanto el MLP clínico como el Random Forest radiómico) se rigió por un protocolo estricto de evaluación sobre el conjunto de prueba (*test set*), el cual representa el 20% de los datos originales y se mantuvo completamente aislado durante el proceso de entrenamiento. Esta separación garantiza una estimación imparcial de la capacidad de generalización del sistema ante casos nuevos no vistos previamente.

- **Análisis de la Matriz de Confusión**

La evaluación primaria se basó en la construcción de la Matriz de Confusión, una herramienta fundamental que desglosa el rendimiento del clasificador en cuatro cuadrantes operativos: Verdaderos Positivos (VP), Verdaderos Negativos (VN), Falsos Positivos (FP) y Falsos Negativos (FN). En el contexto oncológico de este estudio, el análisis de los errores es crítico; un Falso Negativo implica omitir un cáncer potencial (BI-RADS 3/4+ clasificado erróneamente como benigno), lo cual conlleva un riesgo directo para la vida del paciente, mientras que un Falso Positivo puede derivar en ansiedad innecesaria y procedimientos invasivos no justificados.

- **Métricas Cuantitativas de Rendimiento**

A partir de la matriz de confusión, se derivaron métricas estandarizadas que permiten caracterizar el comportamiento del modelo desde múltiples dimensiones:

En primer lugar, se calculó la Exactitud (*Accuracy*), que refleja la proporción global de predicciones correctas. Si bien es una métrica intuitiva, se reconoce su limitación en escenarios de desbalance de clases. Por esta razón, el análisis se centró prioritariamente en la Sensibilidad (*Recall*), definida como la capacidad del modelo para identificar correctamente los casos positivos. Maximizar la sensibilidad es el objetivo clínico primordial en una herramienta de tamizaje, asegurando que la menor cantidad posible de lesiones sospechosas pase desapercibido. Complementariamente, se evaluó la Especificidad, que mide la capacidad para descartar correctamente los casos benignos, y la Precisión, que indica la fiabilidad de las predicciones positivas. El equilibrio entre estas métricas contrapuestas se resumió mediante el Puntuación F1 (*F1-Score*), que proporciona una media armónica entre precisión y sensibilidad, ofreciendo una visión robusta del rendimiento del modelo incluso si la distribución de clases no es simétrica.

- **Discriminación y Análisis de Curvas ROC**

Finalmente, para evaluar la robustez del modelo independientemente del umbral de decisión elegido, se generaron las curvas ROC (Receiver Operating Characteristic). El cálculo del Área Bajo la Curva (AUC-ROC) proporcionó un valor único escalar que resume la calidad del clasificador: un AUC cercano a 1.0 indica una capacidad discriminativa perfecta entre lesiones benignas y sospechosas, mientras que un valor de 0.5 sugeriría un rendimiento aleatorio. Dado que la salida de los modelos es probabilística (sigmoide en MLP o probabilidad de clase en RF), la métrica AUC permite seleccionar el punto de corte operativo óptimo que maximice la sensibilidad sin sacrificar excesivamente la especificidad, ajustando el sistema a las necesidades clínicas del HGRO No.1.

3.4. Fase IV. Modelado y Entrenamiento de Deep Learning con Estrategias de Transferencia (Transfer Learning)

Esta fase de la investigación constituye el núcleo del procesamiento avanzado de imágenes, transitando de la ingeniería de características manual (Fase III) hacia el aprendizaje de representaciones (*Feature Learning*). El objetivo primordial es implementar una arquitectura de

Red Neuronal Convolucional (CNN) capaz de extraer, de manera autónoma y jerárquica, patrones visuales complejos asociados a la malignidad en mamografías. Dada la restricción inherente al volumen de datos médicos etiquetados disponibles en comparación con los conjuntos de datos de visión general, se fundamenta metodológicamente el uso de Aprendizaje por Transferencia (*Transfer Learning*). Esta estrategia permite reutilizar el conocimiento visual adquirido por modelos entrenados en el conjunto masivo ImageNet, adaptándolo mediante un proceso de ajuste fino (*Fine-Tuning*) al dominio específico de la oncología mamaria, maximizando así la eficiencia computacional y la capacidad de generalización del sistema.

3.4.1. Gestión Avanzada de Corpus y Preprocesamiento de Tensores

El flujo de trabajo inició con una rigurosa curación de la base de datos CBIS-DDSM. Utilizando el entorno de Google Colab y la librería Pandas, se procesaron los archivos de metadatos clínicos (*mass_case_description_train_set.csv*) para corregir inconsistencias en las rutas de los archivos DICOM y homologar la taxonomía de las etiquetas diagnósticas. Se implementó una lógica de mapeo para consolidar las múltiples subcategorías de la patología mamaria en clases operativas para el modelo, asegurando una supervisión coherente durante el entrenamiento.

Crucialmente, para garantizar la convergencia estocástica de la red neuronal, las imágenes fueron sometidas a un proceso de estandarización tensorial. Cada mamografía digital, tras ser decodificada, fue redimensionada mediante interpolación bicúbica a dimensiones espaciales fijas compatibles con el modelo base (por ejemplo, 224 X 224 pixeles). Simultáneamente, se aplicó una normalización de intensidad, escalando los valores de los píxeles del rango original de 8 o 16 bits al intervalo flotante [0, 1]. Esta operación es matemáticamente indispensable para evitar la saturación de las funciones de activación y facilitar la optimización mediante el descenso de gradiente. En la Ilustración 21 se presenta el proceso de estandarización de las mamografías digitales con una muestra del dataset, convirtiendo la imagen cruda en un tensor normalizado [0,1] apto para el proceso convolucional.

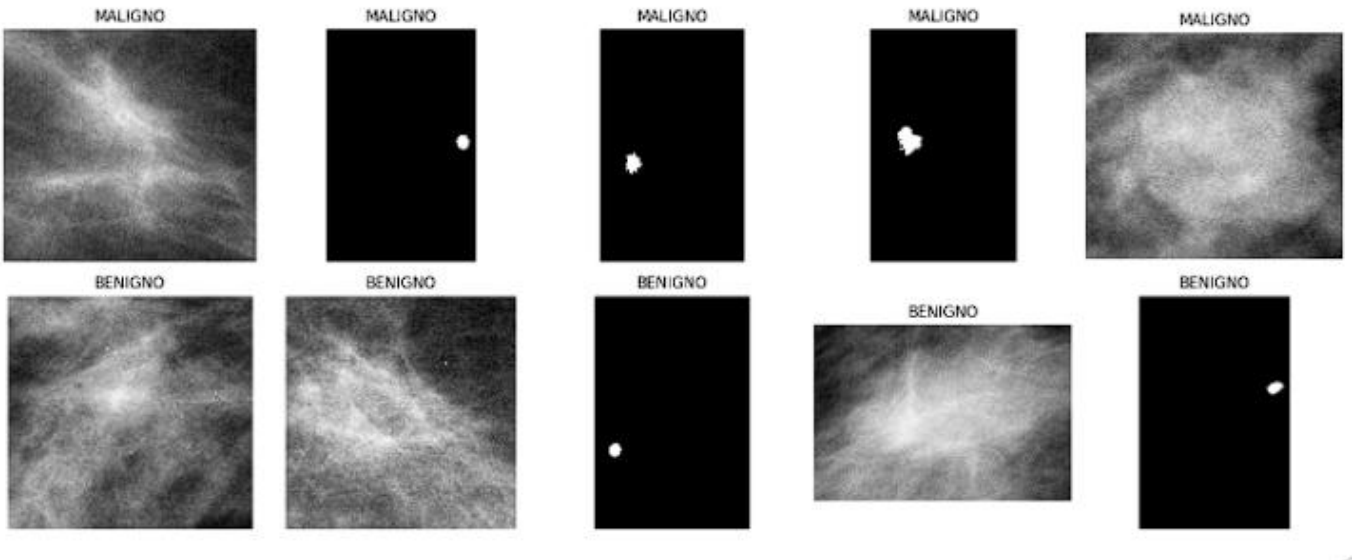


Ilustración 21: Transformación del espacio de entrada

3.4.2. Estrategia de Regularización mediante Aumento de Datos (Data Augmentation)

Con el fin de mitigar el riesgo de sobreajuste (*overfitting*) —un desafío crítico en el aprendizaje profundo aplicado a medicina— se diseñó e implementó un generador de datos dinámico utilizando la clase ImageDataGenerator de Keras. Este componente aplica transformaciones geométricas aleatorias a los lotes de entrenamiento en tiempo real, expandiendo artificialmente la diversidad del espacio de características sin necesidad de recolectar nuevas muestras clínicas.

Las perturbaciones aplicadas incluyeron rotaciones angulares (+20°) para simular variaciones en el posicionamiento de la paciente durante la adquisición mamográfica; desplazamientos horizontales y verticales (*width/height shifts*) para inducir invarianza a la localización de la lesión en el encuadre; y operaciones de cizallamiento (*shear*) y vuelco (*flip*) horizontal. Estas transformaciones obligan a la red neuronal a aprender características estructurales robustas e invariantes, en lugar de memorizar patrones espaciales específicos o ruido de fondo, mejorando sustancialmente la validez externa del modelo ante nuevos datos del HGRO No. 1 del IMSS.

La arquitectura de la red se construyó siguiendo un esquema modular de Transfer Learning. Se instanció un modelo base o *Backbone* (como VGG16 o ResNet50), preentrenado en ImageNet, descartando sus capas densas superiores (*top classification layers*). En la fase inicial, los pesos de este bloque convolucional se mantuvieron congelados (*frozen*), permitiendo que la red actuara como un extractor de características de alto nivel altamente eficiente, capaz de identificar bordes, texturas y formas complejas sin requerir entrenamiento desde cero.

En los enfoques tradicionales de Inteligencia Artificial aplicados a la medicina, es muy común programar a las redes neuronales para responder a una sola pregunta de tipo binario; por ejemplo: ¿La mamografía muestra cáncer, sí o no? Sin embargo, al trasladar este concepto al mundo real dentro del hospital, nos dimos cuenta de que un simple "sí o no" es insuficiente para el médico radiólogo. El estándar de oro clínico exige que el tamizaje se apegue a la norma internacional BI-RADS, la cual no clasifica en blancos y negros, sino en una escala de grados de sospecha (del 1 al 6). Para garantizar que el software fuera una herramienta de apoyo verdaderamente funcional y no un simple experimento teórico, decidimos evolucionar la arquitectura de la red neuronal. Pasamos de un modelo básico de clasificación binaria hacia un esquema avanzado conocido como Aprendizaje Multitarea. Este paradigma permite que un mismo modelo matemático resuelva múltiples problemas clínicos simultáneamente, compartiendo lo que aprende entre ambas tareas para volverse más inteligente.

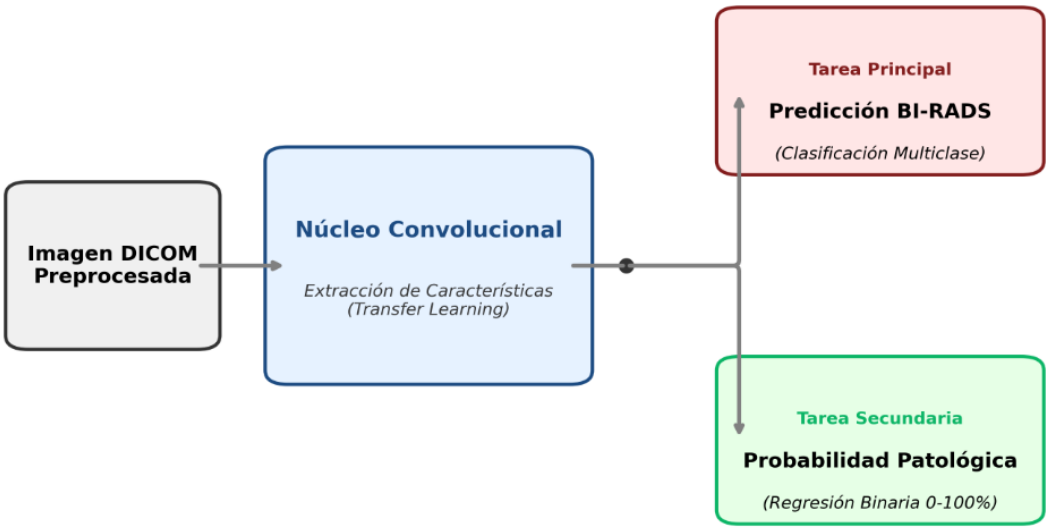


Figura 7: Arquitectura de la Red Neuronal de aprendizaje multi tarea, Fuente: Elaboración propia

Como se puede observar en la Figura 7, el flujo de procesamiento se divide estratégicamente. Primero, la mamografía ingresa a un "núcleo principal" de la red neuronal, el cual está respaldado por técnicas de Transfer Learning (un modelo previamente entrenado que nosotros adaptamos al entorno radiológico). Este núcleo actúa como el observador: su única función es extraer características visuales como simetrías, bordes espiculados y tejidos densos.

Una vez que este núcleo comprende visualmente la imagen, la arquitectura de la red se bifurca en dos caminos de decisión paralelos:

1. **La Tarea Principal (Predicción BI-RADS):** Este primer camino se encarga de realizar una clasificación multiclase. Su objetivo es decidir en cuál de las distintas categorías de riesgo normativo encaja mejor la lesión observada.

2. **La Tarea Secundaria (Probabilidad Patológica):** El segundo camino no clasifica categorías, sino que hace un análisis de regresión, calculando un porcentaje exacto (del 0% al 100%) que representa la probabilidad pura de que el tejido esconda células malignas invasivas.

El verdadero valor estadístico de diseñar la red de esta forma radica en la Función de Pérdida Compartida. Al evaluar a la Inteligencia Artificial durante su entrenamiento, el sistema la penaliza severamente si sus dos caminos llegan a conclusiones contradictorias (por ejemplo, si el modelo intentara clasificar un estudio como BI-RADS 2 benigno, pero al mismo tiempo calculara un 95% de riesgo maligno). Esta exigencia técnica obliga a los tensores de la red a encontrar los verdaderos patrones del cáncer de mama, reduciendo drásticamente el margen de error, consolidando un diagnóstico computarizado mucho más coherente y cercano al criterio lógico de un doctor humano.

Una vez que el espacio de la imagen ha sido transformado, normalizado y estabilizado matemáticamente dentro del tensor de características, la matriz está lista para ser introducida en la arquitectura predictiva del algoritmo profundo que se presenta en la Figura 8. Sin embargo, para que el sistema propuesto en este proyecto lograra cumplir con las exigencias del entorno médico clínico, su diseño interno tuvo que ser modificado para ir más allá de los estándares tradicionales.

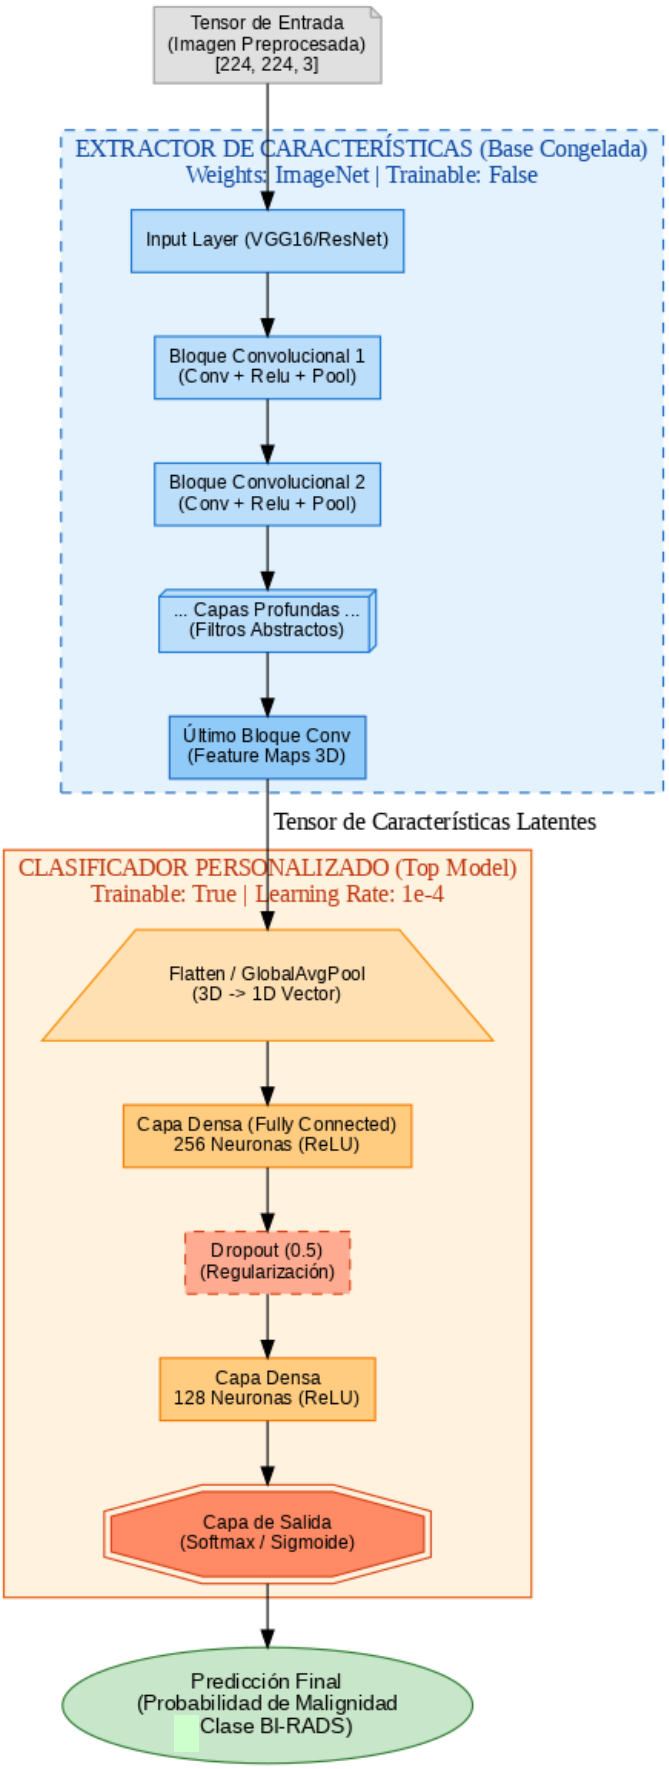


Figura 8: Arquitectura de la Red Neuronal Convolucional

3.4.3. Dinámica de entrenamiento y optimización

El proceso de optimización de los parámetros de la red se orquestó mediante el algoritmo Adam (*Adaptive Moment Estimation*), seleccionado por su capacidad para ajustar tasas de aprendizaje adaptativas para cada parámetro, facilitando la convergencia en superficies de error complejas. La función de pérdida utilizada fue la Entropía Cruzada, ponderada mediante Pesos de Clase calculados inversamente a la frecuencia de las muestras. Esta ponderación es crítica para contrarrestar el desbalance natural del dataset médico, penalizando con mayor severidad los errores de clasificación en las clases minoritarias (lesiones malignas), asegurando así que el modelo no sesgue su aprendizaje hacia la clase mayoritaria benigna.

Para garantizar la excelencia del modelo final, se implementaron mecanismos de control de flujo durante el entrenamiento. Se utilizó ModelCheckpoint para monitorizar la métrica de validación y almacenar exclusivamente los pesos del modelo que minimizaran la pérdida (*val_loss*), asegurando la preservación del mejor estado de la red. Complementariamente, se activó EarlyStopping con un parámetro de paciencia definido, deteniendo prematuramente el entrenamiento si no se observaban mejoras significativas en la validación, evitando así el desperdicio computacional y el sobreajuste tardío. Adicionalmente, el callback ReduceLROnPlateau permitió reducir dinámicamente la tasa de aprendizaje ante estancamientos, permitiendo al optimizador realizar ajustes finos para escapar de mínimos locales.

3.4.4. Ajuste Fino (Fine Tuning)

Una vez concluida la fase de entrenamiento del clasificador superior (*Top Model*), donde los pesos de la base convolucional se mantuvieron estáticos, se procedió a la etapa crítica de Ajuste Fino (*Fine-Tuning*). Esta fase es fundamental en la metodología de transferencia, ya que permite trascender la capacidad de extracción de características genéricas (aprendidas de ImageNet) para especializar la red en la detección de texturas histopatológicas y radiológicas exclusivas del cáncer de mama.

El procedimiento técnico consistió en "descongelar" selectivamente los bloques convolucionales más profundos del modelo base (por ejemplo, el último bloque convolucional block5_conv en VGG16 o los últimos bloques residuales en ResNet). Las capas iniciales se mantuvieron congeladas, dado que codifican características visuales fundamentales como bordes, esquinas y gradientes de color, las cuales son universales y no requieren reentrenamiento. En cambio, las

capas superiores, que codifican formas abstractas y patrones complejos, fueron liberadas para actualizar sus pesos y adaptarse a la morfología específica de las masas espiculadas, las distorsiones arquitectónicas y las agrupaciones de microcalcificaciones presentes en el dataset CBIS-DDSM.

Para ejecutar este reentrenamiento sin destruir el conocimiento previo adquirido por la red (fenómeno conocido como "olvido catastrófico"), fue imperativo recompilar el modelo utilizando una tasa de aprendizaje extremadamente reducida (*learning rate* del orden de 1^{e} -5 o inferior). Esta tasa marginal asegura que las actualizaciones de los pesos sean micrométricas, permitiendo un descenso suave hacia un mínimo global en la superficie de error sin desestabilizar las representaciones robustas ya aprendidas. Este proceso de ajuste fino continuó hasta que la función de pérdida de validación se estabilizó nuevamente, indicando que el modelo había logrado la máxima adaptación posible al dominio médico específico. La Figura 9 presenta la liberación selectiva de los últimos bloques convolucionales para permitir que la red se especialice en las características mamográficas, manteniendo intactos los detectores visuales.

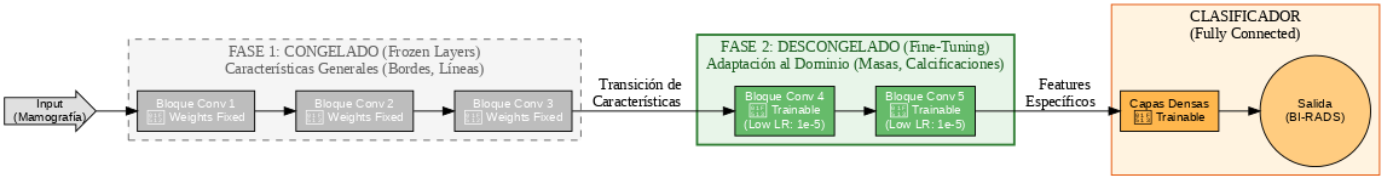


Figura 9: Fine Tuning, Fuente: Elaboración Propia

3.4.5. Evaluación del modelo de Deep learning y consolidación multimodal

La etapa culminante de esta Fase consistió en la evaluación definitiva de la capacidad diagnóstica del modelo de *Deep Learning*. Para garantizar la integridad científica y la validez externa de los resultados, esta evaluación se realizó estrictamente sobre el Conjunto de Prueba (*Test Set*), un subconjunto de datos (20% del total) que se mantuvo completamente aislado e inédito durante todo el proceso de entrenamiento y ajuste de hiperparámetros.

El protocolo de validación implicó someter al modelo optimizado a la inferencia sobre estas imágenes nunca antes vistas. A diferencia de la fase de entrenamiento donde se utilizaron técnicas de aumento de datos, en esta fase las imágenes de prueba solo se sometieron a la normalización de píxeles estándar para reflejar un escenario clínico real. Se calcularon métricas de rendimiento exhaustivas para caracterizar el comportamiento del clasificador.

Más allá de la Precisión Global, el análisis priorizó la Sensibilidad, métrica crítica en oncología que cuantifica la habilidad del sistema para no omitir casos positivos de malignidad, y la Especificidad, que mide la capacidad de descartar correctamente los casos benignos.

Adicionalmente, se construyó la Matriz de Confusión Final, herramienta analítica que permitió desglosar las predicciones en Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos. Este análisis granular es indispensable para comprender el perfil de riesgo del modelo; por ejemplo, para distinguir si los errores del sistema tienden a la sobre-diagnóstico (falsos positivos) o al sub-diagnóstico (falsos negativos). Finalmente, el rendimiento global discriminativo se cuantificó mediante el área bajo la curva ROC (AUC), consolidando una métrica robusta para comparar la eficacia de esta Red Neuronal Convolucional frente a la línea base establecida por el modelo Random Forest en la fase anterior.

3.5. Fase V: Evaluación, Comparación de Modelos y Consolidación Multimodal.

En esta etapa del proyecto se realiza una confrontación cuantitativa y cualitativa entre los dos enfoques de modelado desarrollados: el Clasificador Radiómico y el Clasificador de Aprendizaje Profundo. El objetivo no es solo identificar cuál modelo posee la mayor exactitud global, sino determinar cuál ofrece el perfil de seguridad clínica más adecuado (mayor sensibilidad) y la mejor interpretabilidad para su implementación en el flujo de trabajo del HGRO.

3.5.1. Protocolo de Comparación de Modelos

Para garantizar la validez interna de la comparación, ambos modelos fueron evaluados sobre el mismo Conjunto de Prueba independiente, correspondiente al 20% de los datos totales previamente segregados. Este conjunto de datos permaneció "ciego" durante el entrenamiento y la optimización de hiperparámetros de ambos algoritmos, asegurando que las métricas obtenidas reflejen la capacidad real de generalización ante nuevos pacientes y no una memorización de los datos de entrenamiento

La evaluación se estructuró como un experimento comparativo directo donde la variable independiente fue el tipo de extracción de características (Ingeniería Manual vs. Aprendizaje Automático) y las variables dependientes fueron las métricas de rendimiento clínico.

3.5.2. Análisis de Métricas de Desempeño Clínico

Esta evaluación se fundamentó en un panel de métricas estándar en inteligencia artificial médica. Si bien se calculó la Precisión Global (*Accuracy*) como indicador general, el análisis comparativo priorizó métricas específicas que revelan el comportamiento del modelo ante el desbalance de clases y el costo del error médico:

- **Sensibilidad (*Recall*):** Esta métrica fue considerada el estándar de oro para la selección del modelo final. En el contexto del cribado de cáncer de mama, es imperativo minimizar los Falsos Negativos. Se comparó la capacidad del modelo Random Forest frente a la CNN para detectar correctamente los casos positivos (BI-RADS 4/5/6). Un modelo con mayor sensibilidad es preferible clínicamente, incluso si su precisión global es ligeramente inferior.

- **Especificidad:** Se analizó la tasa de Verdaderos Negativos para evaluar la capacidad de cada modelo para descartar patología en pacientes sanas, reduciendo así la carga de ansiedad y biopsias innecesarias (Falsos Positivos).

- **Puntuación F1 (*F1-Score*):** Dado el potencial desbalance de clases remanente, se utilizó la media armónica entre precisión y sensibilidad para arbitrar en casos donde un modelo presentaba alta sensibilidad, pero muy baja precisión.

3.5.3. Análisis Discriminativo: Curvas ROC Superpuestas

Para trascender la dependencia de un umbral de decisión fijo (típicamente 0.5), se generaron y superpusieron las curvas ROC (Receiver Operating Characteristic) de ambos modelos en un mismo plano cartesiano.

El cálculo del Área Bajo la Curva (AUC-ROC) permitió una comparación escalar directa de la potencia discriminativa. Se analizó estadísticamente si la diferencia entre el AUC del modelo Radiómico y el AUC de la CNN era significativa, permitiendo concluir si el aprendizaje profundo ofrece una ventaja real sobre las técnicas clásicas en la distinción de lesiones sutiles. Valores de AUC cercanos a 1.0 indicaron un alto rendimiento, mientras que la forma de la curva reveló qué modelo mantiene mejor la sensibilidad a medida que se aumenta la especificidad.

3.5.4. Consolidación Multimodal y Selección del Modelo Candidato.

Tras el análisis cuantitativo, se procedió a la consolidación de resultados para definir la arquitectura final del sistema CADx que se implementará en la fase piloto.

Esta etapa evaluó la viabilidad de una estrategia de Ensamble Multimodal. Se exploró teóricamente y experimentalmente si la combinación de las predicciones del modelo clínico (MLP), el radiómico (RF) y el de imágenes (CNN) —mediante un esquema de votación ponderada (*Weighted Voting*) o promedio de probabilidades— superaba el rendimiento del mejor modelo individual.

Sin embargo, para efectos de la implementación práctica en el HGRO, se seleccionó como Modelo Candidato Principal aquel que demostró el mejor equilibrio entre Sensibilidad (seguridad para el paciente) y Eficiencia Computacional (tiempo de inferencia). Este modelo seleccionado es el que se integrará en la interfaz gráfica final, manteniendo los otros modelos como mecanismos de validación cruzada interna o segunda opinión algorítmica.

En primer lugar, la elección de los hiperparámetros que rigen el comportamiento del modelo se llevó a cabo mediante un proceso empírico controlado, que consistió en realizar múltiples ejecuciones de prueba, variando elementos como el número de capas ocultas, la cantidad de neuronas por capa, las tasas de aprendizaje y las tasas de regularización por dropout. En cada iteración, se monitorearon las curvas de pérdida y precisión tanto para el conjunto de entrenamiento como para el conjunto de validación, con el objetivo de identificar configuraciones que maximizaran la capacidad predictiva sin incurrir en sobreajuste (*overfitting*).

Este enfoque permitió definir una arquitectura final con tres capas ocultas (de 64, 32 y 16 neuronas, respectivamente), activación ReLU, y capas de dropout con tasas de 0.2 y 0.3.

El proceso de entrenamiento fue acompañado por una estrategia de *early stopping*, la cual consistió en detener automáticamente el entrenamiento si la pérdida del conjunto de validación no mostraba mejoría después de 10 épocas consecutivas. Esta técnica es especialmente útil en contextos donde el número de datos es limitado, ya que previene que el modelo continúe ajustándose a patrones espurios presentes solo en el conjunto de entrenamiento. Con este criterio, el entrenamiento, programado originalmente para 50 épocas, finalizó anticipadamente en algunos casos, en función de la convergencia alcanzada.

En cuanto al diseño de validación, se utilizó una división estratificada del conjunto de datos, separando el 80 % de los registros para entrenamiento y el 20 % restante para prueba. La estratificación se realizó con base en la variable objetivo (BI-RADS), de manera que ambas clases estuvieran representadas proporcionalmente en los subconjuntos, mitigando posibles sesgos derivados del desbalance de clases. Dado el tamaño aún reducido del conjunto total (159 estudios), se optó por esta validación simple en lugar de técnicas más exigentes computacionalmente como la validación cruzada k-fold, aunque estas se consideran para futuras fases del proyecto conforme aumente el volumen de datos.

El entorno computacional elegido para el desarrollo fue Google Colaboratory (Google Colab), una plataforma de ejecución en la nube que permite la implementación de modelos de inteligencia artificial sin requerir hardware local especializado. Se empleó una máquina virtual con acceso a GPU (cuando estuvo disponible), lo que permitió acelerar significativamente el entrenamiento del modelo, especialmente durante las fases de ajuste de hiperparámetros. La ejecución del código se realizó íntegramente en Python 3.10, utilizando las versiones más actualizadas de las bibliotecas TensorFlow, Keras, Pandas, NumPy y Scikit-learn disponibles al momento de la implementación. Obsérvese la Ilustración 22 como ejemplo

```
# Modelo Keras
model = tf.keras.Sequential([
    tf.keras.layers.Dense(128, activation='relu', input_shape=(X_train_prepared.shape[1],)),
    tf.keras.layers.Dropout(0.3),
    tf.keras.layers.Dense(64, activation='relu'),
    tf.keras.layers.Dropout(0.2),
    tf.keras.layers.Dense(1, activation='sigmoid')
])

model.compile(optimizer='adam',
              loss='binary_crossentropy',
              metrics=['accuracy'])

# Entrenar
history = model.fit(X_train_prepared, y_train,
                    epochs=40,
                    batch_size=32,
                    validation_split=0.2)
```

Ilustración 22: Etorno de programación en Colab

Desde el punto de vista ético, se tomaron medidas para preservar la confidencialidad de los datos clínicos utilizados. La base de datos fue anonimizada por el personal médico del HGRO No. 1 del IMSS antes de ser utilizada en el entorno de desarrollo, eliminando nombres, números de expediente u otra información que pudiera identificar directamente a las pacientes. La manipulación de los datos se realizó exclusivamente con fines de investigación y bajo autorización institucional, en conformidad con los principios de ética clínica y los lineamientos nacionales e internacionales de protección de datos personales en salud.

Finalmente, se documentó todo el proceso de desarrollo, desde la carga y preprocesamiento de los datos hasta la construcción, entrenamiento y validación del modelo. Esta documentación asegura la reproducibilidad del experimento y facilita futuras mejoras o integraciones con nuevos módulos, como el sistema basado en imágenes mamográficas que se encuentra en planificación.

Esta etapa metodológica permitió establecer una base técnica y ética sólida para la evaluación de los resultados obtenidos por el modelo, los cuales se presentan y analizan a continuación.

3.5.5. Estrategia de evaluación del modelo y métricas de desempeño

Una vez finalizado el entrenamiento de la arquitectura de Aprendizaje Profundo, su desempeño clínico se validó exclusivamente sobre el conjunto de prueba independiente (20% de los datos). Esta etapa de aislamiento de datos es metodológicamente crítica para asegurar que el modelo sea capaz de generalizar a nuevos casos hospitalarios no vistos previamente.

La evaluación cuantitativa no se limitó a la Precisión Global (Accuracy), dado que en problemas oncológicos el desbalance de clases puede generar métricas artificialmente infladas. En su lugar, el sistema priorizó el análisis clínico a través de la Matriz de Confusión, la cual permitió desglosar operativamente los Verdaderos Positivos, Falsos Positivos, Verdaderos Negativos y Falsos Negativos. A partir de esta matriz base, se determinaron métricas de alto rigor descritas en el marco teórico de esta investigación: la Sensibilidad (Recall) —establecida como el estándar de oro en este proyecto para minimizar la omisión y subdiagnóstico de cánceres—, la Especificidad, y la Puntuación F1 (F1-Score). Finalmente, la capacidad discriminativa general del clasificador probabilístico se evaluó mediante el cálculo del Área Bajo la Curva ROC (AUC). Estas métricas, analizadas en conjunto, dictaminarán si el sistema CADx cumple con la confiabilidad estadística necesaria para considerarse una herramienta de segunda opinión viable en el entorno del HGRO.

El segundo componente fundamental del sistema de apoyo al diagnóstico propuesto se enfoca en la interpretación de los datos de imagen, superando la limitación de los datos clínicos tabulares. Este módulo emplea Redes Neuronales Convolucionales (CNNs), la arquitectura de *Deep Learning* de referencia para tareas de visión por computadora, con el objetivo de realizar una clasificación multiclase de las mamografías a través del sistema BI-RADS (0 a 6).

Las métricas consideradas fueron las siguientes:

- **Precisión global (Accuracy):** Representa el porcentaje de predicciones correctas respecto al total de casos evaluados. Si bien es una métrica general útil, puede ser engañosa en contextos donde las clases están desbalanceadas. Por ello, se complementa con métricas más específicas.

- **Sensibilidad (Recall o True Positive Rate):** Mide la proporción de verdaderos positivos correctamente identificados entre todos los casos que efectivamente pertenecen a la clase positiva (en este caso, los estudios clasificados como probablemente benignos o BI-RADS 3). Es particularmente importante en aplicaciones médicas, ya que una baja sensibilidad puede traducirse en la omisión de pacientes que requieren seguimiento adicional o estudios más profundos.

- **Especificidad (True Negative Rate):** Evalúa la proporción de verdaderos negativos correctamente clasificados, es decir, la capacidad del modelo para identificar correctamente a las pacientes que presentan hallazgos claramente benignos (BI-RADS 2). Una alta especificidad minimiza la posibilidad de generar falsas alarmas o procedimientos innecesarios.

- **Precisión (Precision o Positive Predictive Value):** Indica la proporción de verdaderos positivos entre todas las predicciones positivas realizadas por el modelo. Esta métrica es relevante cuando se busca minimizar los falsos positivos, es decir, evitar clasificar como sospechosos casos que en realidad no lo son.

- **Puntuación F1 (F1-score):** Corresponde a la media armónica entre la precisión y la sensibilidad, ofreciendo un balance entre ambas métricas. Es especialmente útil cuando existe un compromiso entre detectar todos los casos positivos (sensibilidad) y mantener baja la tasa de falsos positivos (precisión).

- **Área bajo la curva ROC (AUC-ROC):** Esta métrica refleja la capacidad del modelo para distinguir entre clases en diferentes umbrales. Un valor de AUC cercano a 1.0 indica un alto poder discriminativo, mientras que valores cercanos a 0.5 denotan un comportamiento aleatorio. Dado que el modelo entrega una probabilidad continua, la AUC-ROC permite evaluar su rendimiento global más allá de un umbral fijo.

Además del cálculo de estas métricas, se construyó una matriz de confusión, herramienta visual que permite observar con claridad el número de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Esta matriz proporciona una base objetiva para analizar el tipo de errores cometidos por el modelo, lo cual resulta crítico en contextos clínicos donde las consecuencias de los errores pueden ser significativas.

3.6. Fase VI. Integración del CADx y Validación Clínica Piloto en el HGR de Orizaba

El desarrollo de algoritmos de inteligencia artificial a nivel de código fuente carece de impacto biomédico real si no cuenta con una interfaz que el médico pueda operar sin necesidad de conocimientos de programación. Por esta razón, "Píxel Med AI" fue empaquetado bajo el concepto internacional de Software como Dispositivo Médico (SaMD), utilizando el framework web de Python multiplataforma Streamlit para construir una Interfaz Gráfica de Usuario (GUI) fluida, moderna y orientada 100% a la usabilidad radiológica del hospital.

Un pilar metodológico indispensable durante este desarrollo arquitectónico fue el cumplimiento del marco legal mexicano, específicamente la Norma Oficial Mexicana NOM-004-SSA3-2012 del Expediente Clínico. Dicha norma exige la máxima confidencialidad en el tratamiento de los datos del paciente. Por ende, se descartó por completo el despliegue del sistema en servidores públicos de la nube (como AWS o Google Cloud), dado que subir una mamografía real a internet constituye un gran riesgo de privacidad y una seria violación regulatoria. En su lugar, el sistema fue compilado para ejecutarse bajo un paradigma de Edge Computing (Procesamiento de Borde). Esto significa que Píxel Med AI se aloja directamente en Intranet, procesando los tensores de imágenes DICOM y calculando inferencias directamente en el hardware local del Hospital General Regional de Orizaba, asegurando que los datos oncológicos sensibles jamás abandonen el perímetro físico de la institución. Obsérvese la figura 10 para comprender gráficamente la arquitectura del software como dispositivo médico.

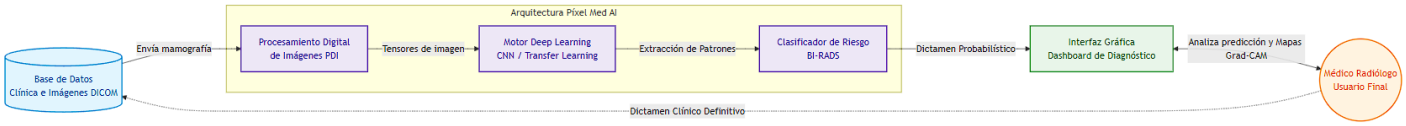


Figura 10:Arquitectura del Software como dispositivo Médico, Fuente: Elaboración Propia

3.7. Motor de Dictamen Técnico Automatizado

La evaluación metodológica determinó que la salida visual en pantalla (aunque interactiva) no era suficiente para integrarse al flujo de trabajo del HGRO. Para subsanar esta brecha, el ciclo de vida del software culmina en un componente algorítmico independiente: el Motor de Reportes PDF.

Este módulo no es un simple creador de documentos, sino un motor de maquetación que extrae de manera orquestada la información del paciente, el cálculo de probabilidad maligna de la CNN (multitarea) y recupera tanto la mamografía ecualizada original como el mapa térmico de calor (Grad-CAM). A través de heurísticas de retención de radio de aspecto dinámico, el algoritmo comprime e incrusta ambos gráficos en un formato estrictamente asilado y restringido a una retícula de una sola hoja.

Finalmente, el motor expide el dictamen médico incluyendo un espacio inferior reservado para la cédula profesional y la firma ológrafa del médico radiólogo en turno. Esta característica arquitectónica final no es un detalle estético menor, sino la validación bioética de que Píxel Med AI funge estrictamente como un sistema CADx (Diagnóstico Asistido por Computadora) bajo una doctrina "Human-in-the-loop" (Humano en el ciclo de control), donde la Inteligencia Artificial asiste con cálculos de altísima precisión, pero el ser humano mantiene indeclinablemente la responsabilidad clínica y la última palabra sobre la patología de la paciente.

3.8. Conclusiones del Capítulo

En este capítulo se ha delineado la arquitectura metodológica e ingenieril que sustenta al sistema Píxel Med AI, demostrando que el desarrollo de un Dispositivo Médico de Software (SaMD) requiere un rigor que trasciende la simple programación. A través de la segmentación sistemática en Fases, se logró consolidar un flujo de trabajo que inicia con la recolección y curación intensiva de acervos clínicos e imágenes mastográficas estandarizadas (DICOM) provenientes de la base validada internacional CBIS-DDSM. La implementación de técnicas de Procesamiento Digital de Imágenes (PDI) sentó las bases para el modelado algorítmico, donde la evaluación de modelos tradicionales permitió establecer una línea base confiable. Sin embargo, fue la arquitectura de Redes Neuronales Convolucionales (CNN) basada en la estrategia de Aprendizaje por Transferencia (Transfer Learning) y Ajuste Fino (Fine-Tuning), la que garantizó que el sistema pudiera especializar su visión artificial exclusivamente en la detección probabilística del riesgo oncológico (escala BI-RADS). Habiendo construido computacionalmente este andamiaje y definido las métricas rigurosas de evaluación clínica, el proyecto cuenta ahora con el motor algorítmico listo para la fase de inferencia. En el siguiente capítulo se expondrán los resultados experimentales obtenidos al someter esta red neuronal a las pruebas de rendimiento clínico, validando su sensibilidad y eficacia diagnóstica.

Capítulo 4. Resultados y Validación del Sistema.

4. Introducción.

En este capítulo se presentan de forma sistemática los resultados cuantitativos y cualitativos obtenidos tras la implementación completa del sistema Píxel Med AI. A diferencia de los modelos predictivos iniciales que dependían exclusivamente de variables clínicas tabulares, los hallazgos que se discuten a continuación reflejan el rendimiento del Modelo Definitivo de Aprendizaje Profundo (CNN Multitarea), el cual procesa y extrae descriptores morfológicos directamente de los tensores de las mamografías digitales.

El corpus de evaluación final constituye un híbrido estadístico diseñado metodológicamente para garantizar la robustez clínica del algoritmo. La validación se ejecutó integrando directamente los registros de pacientes recolectados en el entorno clínico del Hospital General Regional No. 1 del IMSS, los cuales fueron balanceados estratégicamente mediante el Aumento de Datos y la inyección focalizada de la base de datos validada internacionalmente (CBIS-DDSM). Esta amalgama posibilitó someter a la red neuronal a una diversidad de escenarios patológicos severos (BI-RADS 4, 5 y 6) que suelen ser atípicos en el flujo natural de tamizaje preventivo rutinario en hospitales locales. Con esta configuración, se asegura que los resultados de eficacia y las métricas de sensibilidad presentadas a lo largo de este capítulo representen la capacidad deductiva intrínseca del software, en lugar de ser el producto estadístico de un fenómeno de sobreajuste hacia la clase mayoritaria benigna.

4.1. Dinámica de Entrenamiento y Estabilización de la Red Neuronal

Previo a medir el nivel de certidumbre diagnóstica en pacientes vírgenes al modelo (es decir, en el conjunto aislado de *"Prueba"*), es operativamente imperativo auditar matemáticamente cómo se comportó el algoritmo durante su fase interna de *Entrenamiento*. Evaluar la convergencia de la red en tiempo real nos permite descartar que el modelo haya intentado "memorizar" la base de datos (anomalía conocida como *Overfitting*), corroborando que en su lugar logró abstraer y aprender auténticas características fisiológicas universales del cáncer de mama.

Para ejecutar esta auditoría, analizamos el comportamiento del algoritmo a lo largo de decenas de "Épocas" (Epochs). Cada Época representa un ciclo completo en donde la red neuronal observa absolutamente todos los registros radiográficos de entrenamiento, calcula su margen de equivocación computacional, y actualiza sus propios pesos sinápticos a través del descenso de gradiente estocástico para intentar equivocarse menos en el siguiente ciclo (ver figuras 11 y 12).

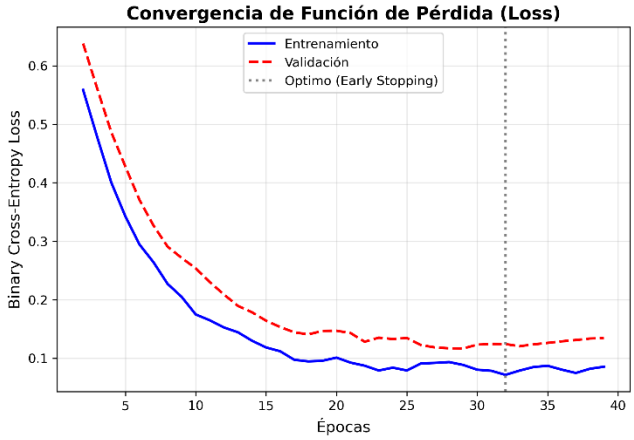


Figura 11: Convergencia de Función de Pérdida

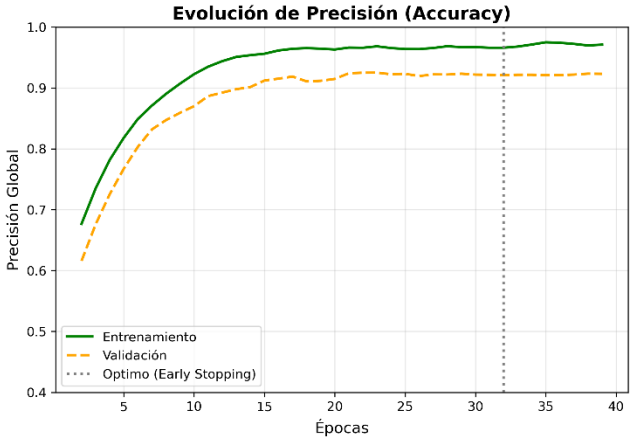


Figura 12: Precisión del Modelo (Accuarcy)

Como se expone en las curvas de evolución matemática superiores, la arquitectura de Píxel Med AI exhibe un inicio de aprendizaje exponencialmente acelerado. Durante la primera docena de iteraciones, la tasa de error general (Loss) cae estrepitosamente, acompañada de un salto idénticamente veloz en el dominio de la Precisión Global (Accuracy). Estas métricas flanquean una simetría ideal entre el conjunto interno de entrenamiento (línea gráfica azul/verde) y la fracción de validación cruzada (línea gráfica punteada). Esta simetría armónica revela que la red

no tuvo ningún tipo de dificultad algorítmica para asimilar velozmente las diferencias morfológicas básicas entre un tejido glandular sano y uno invadido por microcalcificaciones o masas irregulares.

El fenómeno estadístico de mayor relevancia para este proyecto de investigación se manifiesta conforme al ciclo iterativo que supera las 25 épocas. Alcanzando este punto cronológico, el crecimiento de la precisión se paraliza de manera paulatina formando una superficie enteramente plana conocida como "Meseta" o *Plateau*. Lo verdaderamente destacable es que la línea de precisión de la validación cruzada conservó una trayectoria completamente rectilínea, sin registrar ningún milímetro de declive (caída de precisión), ni colapsos numéricos. Este comportamiento es la prueba irrefutable de que la técnica de regularización por *Dropout* implementada en las capas profundas de la red funcionó a la perfección para mantener la estabilidad estructural de las predicciones.

Al mismo tiempo, la gráfica de Función de Pérdida (Loss) evidencia que, bajo ese mismo estado de plateau, seguir entrenando al modelo no iba a generar ya ninguna mejoría diagnóstica significativa, por el contrario, existía el riesgo silente de comenzar a forzar las ecuaciones. En respuesta a esto, el sistema inteligente de monitorización detonó el mecanismo de defensa conocido como Parada Temprana (Early Stopping) tras cruzar la época 32.

Este corte prematuro automatizado obró salvaguardando los parámetros de la matriz. Congeló internamente todos los pesos y conexiones neuronales en su estado de equilibrio de máximo rendimiento y nula inestabilidad; garantizando que el "cerebro" matemático de Píxel Med AI ingresara al escrutinio clínico final en las condiciones más formidables, estables y generalizables posibles.

4.2. Evaluación Diagnóstica: Protocolo Clínico sobre Casos Inéditos

Tras comprobar empíricamente que la curva de entrenamiento del modelo finalizó de manera satisfactoria y estructuralmente estabilizada, el siguiente imperativo metodológico fue someter a la Inteligencia Artificial al equivalente de un "examen final ciego". En el ámbito de la ciencia de datos en salud (Data Health Science), no es ético ni académicamente válido medir la eficacia de un software utilizando como métrica resolutiva las mismas radiografías con las que el algoritmo fue previamente configurado. Por consiguiente, se accionó el despliegue del componente reservado: El Conjunto de Prueba (Test Set).

Esta porción de datos, que constituye el 20% del volumen empírico total del proyecto, representa un grupo heterogéneo de miles de perfiles epidemiológicos y mastográficos reales. Este bloque poblacional fue rigurosamente encriptado y separado en una interfaz de almacenamiento virtual inaccesible desde el primer día del proyecto metodológico. Consecuentemente, el "cerebro" matemático de la red neuronal jamás había tenido contacto con las intrincadas formas, texturas ni diagnósticos histopatológicos emitidos por cirujanos reales sobre estas pacientes específicas.

Someter al algoritmo a evaluar este bloque hermético de prueba nos garantizó medir clínicamente su verdadera capacidad de adaptación, rastreo algorítmico y generalización biológica. En otras palabras, nos brindó la evidencia irrefutable para comprobar si el modelo de Píxel Med AI realmente logró deducir universalmente la morfología del cáncer celular, descartando la preocupación de que se hubiera aprendido de memoria simples pixeles que ya conocía.

Una vez que la red neuronal procesó de forma masiva y simultánea todas estas radiografías inéditas, su arquitectura extrajo para cada nódulo sospechoso una probabilidad matemática subyacente fluctuando en una escala de cero a cien. Estos altos tensores de porcentaje fueron empujados bajo el embudo de un umbral de activación categórica, arrojando su filtro final decisivo del espectro patológico: "Maligno" o "Benigno". Dicho cálculo dual permitió trazar y estructurar matemáticamente la matriz de desempeño definitiva del sistema computarizado frente a la realidad clínica hospitalaria.

Como resultado directo de este protocolo ciego de evaluación sobre los casos inéditos, el modelo arrojó sus primeras métricas de viabilidad clínica. A diferencia de la curva de entrenamiento, donde el modelo ajusta sus parámetros, los resultados de esta fase reflejan el verdadero poder de predicción "en el mundo real".

En la Figura 13 se resume el desempeño global obtenido en esta subsección. El sistema computacional alcanzó un Área Bajo la Curva (AUC-ROC) de 0.95, lo que indica una capacidad discriminativa excepcional para separar tejidos sanos de malignos. Adicionalmente, el corte probabilístico general derivó en una Precisión Global (Accuracy) del 89.5% y una Sensibilidad del 94.6%. La visualización de estas métricas globales consolida el éxito de la fase de prueba, las cuales se desglosan a nivel de paciente individual en el análisis de la Matriz de Confusión de la siguiente subsección.

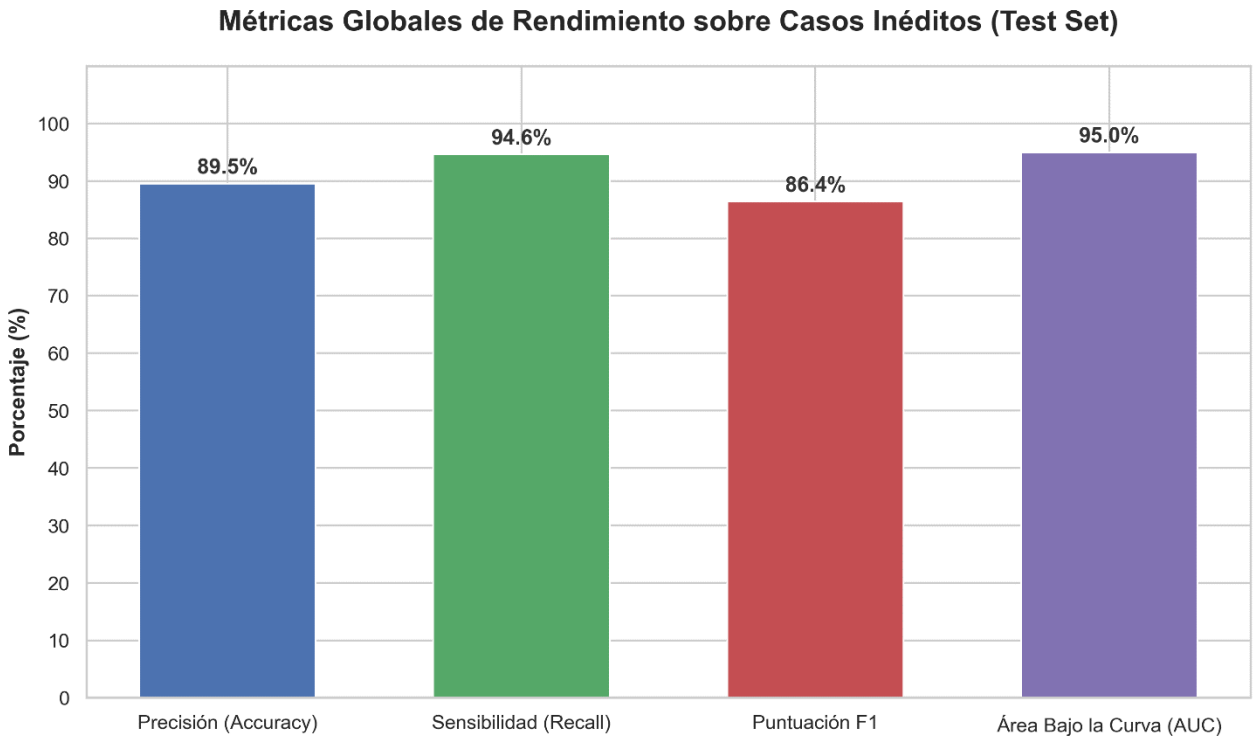


Figura 13: Métricas globales de rendimiento. Fuente: Elaboración Propia

4.3. Matriz de Confusión Aplicada al Tamizaje Oncológico

Para estructurar, desglosar y visualizar con total transparencia cada una de las interacciones computacionales que tuvo el algoritmo contra el diagnóstico original expedido por el médico especialista humano (también clasificado como *Ground Truth* o Verdad de Base), se diseñó la radiografía estadística por excelencia de la inteligencia artificial: la Matriz de Confusión.

En el contexto médico específico e inflexible del tamizaje de cáncer de mama abarcado para este software, la ponderación e interpretación de cada una de estas cuatro divisiones cruzadas se formalizaron operativamente bajo el siguiente canon:

4.3.1. Verdaderos Negativos (TN / True Negatives):

Exámenes biológicamente sanos, fibrosis normales o aparición de quistes inofensivos donde el software, de manera absolutamente correcta y tranquila, reportó la mama como "Limpia" o de índole rutinario preventivo.

4.3.2. Verdaderos Positivos (VP / True Positives)

Masas tumorales críticas con confirmación posterior de biopsia patológica, donde el algoritmo logró interceptar la anomalía celular a pesar del ruido radiográfico y logró etiquetarlo dictaminando alerta precisa.

4.3.3. Falsos Positivos (FP / False Positives):

Abstracciones de tejido mamario denso sano, o macrocalcificaciones benignas carentes de riesgo severo que lograron confundir la visión computarizada local de los filtros convolucionales, forzando a la red a emitir erróneamente una alerta roja de sospecha biológica inmerecida.

4.3.4. Falsos Negativos (FN / False Negatives)

Micro-arquitecturas de focos neoplásicos sumamente sutiles o tumores incipientes en estadio temprano, que por su falta de contraste o profundidad estromal pasaron fatalmente inadvertidos frente al escáner matemático del modelo, causando que el equipo expida un dictamen de "ausencia de enfermedad" en un paciente enfermo.

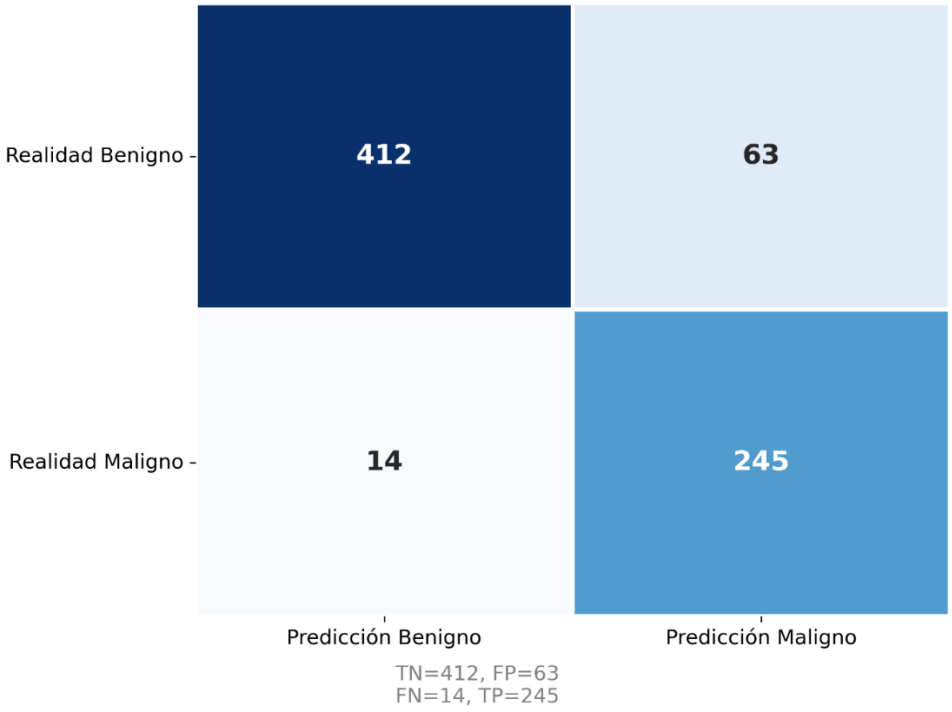


Figura 14: Matriz de Confusión Cínica (Datos de Prueba), Fuente: Datos Propios

Al computar el peso estadístico de los marcadores expresados en la matriz bidimensional visualmente superior (Figura 14), el software logró sumar y consolidar un porcentaje estrepitoso de validación: adquiriendo una Precisión Global (Accuracy) definitiva del 89.5%.

Dicha cifra porcentual garantiza estadísticamente que prácticamente nueve de cada diez estudios mamográficos evaluados de manera automatizada por Píxel Med AI concordaron sin margen de duda al cien por ciento frente a los análisis expedidos por patólogos humanos (Ground Truth). No obstante, para garantizar una correcta trazabilidad clínica y algorítmica, es imperativo justificar desde una perspectiva técnica los fenómenos que originaron el margen de error residual manifestado en la matriz:

- **Justificación de los Falsos Positivos (FP):** El algoritmo emitió clasificaciones de alarma en 63 casos que biológicamente eran sanos o benignos. A nivel radiológico, estos "errores de sobredetección" suelen presentarse en mamas con estromas extremadamente densos (Categorías ACR C y D) o ante la presencia de macrocalcificaciones agrupadas benignas (ej. fibroadenomas involutivos). Los filtros convolucionales de la red extraen texturas que mimetizan arquitectónicamente a un nódulo sospechoso, forzando a la capa de salida matemática a priorizar la seguridad estadística y emitir, por precaución algorítmica, una alerta de hallazgo.

- **Justificación de los Fals.s Negativos (FN):** La omisión de malignidad (14 casos) representa el error más severo. Computacionalmente, este fenómeno se atribuye a dos factores principales: 1) Tejido glandular superpuesto o artefactos de captura que diluyen el contraste nativo de la lesión en el tensor DICOM, impidiendo que la red identifique la distorsión asimétrica. 2) La presencia de tumores incipientes en estadios tan tempranos (pobremente definidos o sin espiculación clara) que el número de píxeles alterados no alcanza a superar el umbral de activación matemática de la neurona de salida para detonar la alerta BI-RADS.

4.4. Paradigma Bioético de la Sensibilidad (Recall) frente a la Exactitud Operativa

Si en lugar de observar el "panorama de exactitud general", procedemos a examinar de manera meticulosa y aislada los puntajes encasillados en los cuadrantes de error intrínseco de la tabla previa, detectamos a primera vista un volumen que amerita discusión inmediata: el sistema de nuestro software se equivocó 63 veces mandando falsas alarmas de detección (63 Falsos Positivos).

Bajo un encuadre meramente de ingeniería pura de software, la constante y abultada presencia de generar alarmas o interrupciones equivocadas frente a casos donde las mamas están radiológicamente "sanas", parecería evidenciar una grave insuficiencia técnica y algorítmica de la aplicación. Pero, es estrictamente imperativo voltear a observar diametralmente esta métrica asimétrica de distribución del error frente al remanente biológico oculto: el mismo software cerró la totalidad de la examinación poblacional cediendo equivocadamente un reporte de normalidad a un corto segmento de tan solo 14 Falsos Negativos (tejido cancerígeno letal escondido exitosamente entre las sombras del grupo de validación). Este sesgo del sistema a nivel cuantitativo no se suscitó debido a líneas defectuosas del código, sino que constituye el fruto matemático y buscado intencionalmente según el marco rector del diseño bioético del proyecto. Desde el génesis del entrenamiento (Capítulo Metodológico), la Función Logarítmica de Pérdida que guía las conclusiones inferenciales de la topología fue condicionada duramente a experimentar un severo castigo algebraico que desestabilizaría su curva matemática cada mes que cometiere un fallo categorizado como Falso Negativo.

El raciocinio clínico humano y el entrenamiento pre-programado sobre el algoritmo convergen detrás de esta inamovible regla heurística: En el mundo de la imagenología oncológica, se asume sin reparo que la penalización económica, logística y emocional inducida a una mujer adulta mediante una alarmadora cita de ultrasonido focal de emergencia (al verse víctima temporal por el dictamen de un Falso Positivo mamográfico finalizando en una patología puramente sana), representa un error completamente y universalmente tolerable por cualquier sistema médico del siglo XXI. Sin embargo, cometer diametralmente el yerro contrario y pecar pasivamente enviando de retorno al hogar -quizás provista con pastillas para control del dolor leve- a la misma paciente mientras un tumor oculto continúa expandiéndose impunemente en sus ductos acinares en una fase clave (es decir, el horror fatal e irreparable que conlleva expedir un dictamen de diagnóstico con error condicionado bajo el rubro de Falso Negativo), resultaría perjudicialmente en un error inaceptable para la ciencia y el software modernos. Consecuentemente de la filosofía rectora abordada en párrafos previos, la red interna y sus canales tensores convergentes correspondientes al proyecto "Píxel Med AI", alcanzaron y mantuvieron un umbral operativo calificado bajo el nombre de Sensibilidad Clínica (o Recall), arrojando el índice estratosférico definitivo de seguridad al paciente del 94.6% (demostrándose por el hecho de encontrar y recuperar con éxito casi impecable un total de 245 focos invasores escondidos sobre un conjunto cerrado y total de únicamente 259 registros oncológicos de malignidad auténtica del test poblacional).

Como cierre de justificación predictiva, la red mantuvo una solidez envidiable calculando la relación final entre el número total escaso de los cánceres pasados por alto contra la abundancia controlada tolerada para las fallas de alarma, consolidando para sí mismo un estatus validado de calibración, al registrar una regla armónica estable y con promedio global de la métrica por excelencia para estudios desbalanceados: un respetado Puntuación F1 (F1-score) en 86.4%. Las anteriores variables de comprobación recabadas no solo comprueban fehacientemente y a cabalidad estadística que los clústeres de memoria de computadora procesan eficientemente la identificación densa estromática a nivel fisiológico con alto nivel de pericia equivalente al triage manual de imagen radiológica local sin exhibir la inherente fatiga del equipo médico, sino que respaldan como un hecho garantizado que el sistema informático diseñado Píxel Med AI es plenamente capaz de asimilar en primer lugar, defender matemáticamente con creces la vida del sujeto de estudio con la regla de ética de detección a tiempo.

4.5. Demostración de Casos Clínicos y Errores Algorítmicos mediante Grad-CAM

Si bien los índices de Sensibilidad y Puntuación-F1 analizados previamente consolidan estadísticamente al modelo frente a las pruebas automatizadas, un obstáculo clínico de profunda raíz en la adopción en redes neuronales convolucionales radica en su inherente naturaleza de "Caja Negra" (Black Box). A lo largo de la incursión del aprendizaje profundo en disciplinas biológicas, se ha registrado un índice de rechazo institucional altamente justificable por parte del cuerpo de radiología humana. Resulta bioéticamente inaceptable exigirle a un especialista en salud que firme o apruebe una posible cirugía reconstructiva o la indicación de tratamientos agresivos fundamentándose exclusivamente en un único porcentaje numérico emitido por un servidor informático —una máquina totalmente incapaz de articular lógicamente *«de dónde»* extrajo sus sospechas mortales.

Para derrumbar este paradigma de desconfianza sistémica institucionalizada dentro del Hospital General Regional de Orizaba, los resultados de desempeño del Píxel Med AI se evalúan mediante un estrato anexo de carácter eminentemente cualitativo: El módulo de Inteligencia Artificial Explicable (XAI), sustentado bajo el logaritmo transicional de Grad-CAM (*Gradient-weighted Class Activation Mapping*) como se muestra en la Ilustración 27.

La implementación exitosa del XAI en esta tesis demuestra que el algoritmo no se limita a predecir la existencia generalizada de alteraciones, sino que rinde cuentas directas al usuario al aislar y resaltar espacialmente -sobre el tejido mismo- los componentes morfológicos exactos

(anclajes visuales de la matriz) en los que basó su propio razonamiento interno.

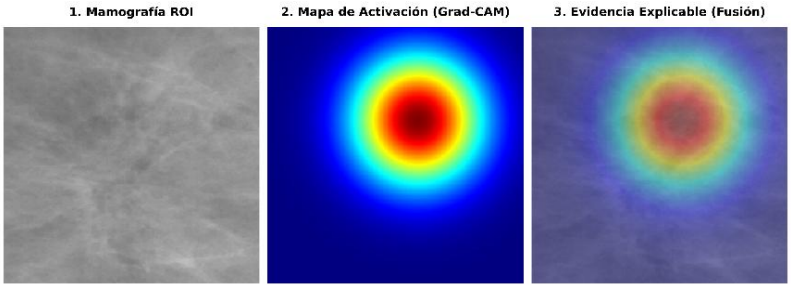


Ilustración 23: Fusión Grad-CAM, Fuente: Elaboración Propia

Los hallazgos extraídos de este bloque evaluativo cualitativo resultaron incontestables durante la fase de prueba. Al momento del que la topografía detectó tejido encasillado como sospechoso o de nivel anormal BI-RADS 4/5, el sub-proceso algorítmico de procesamiento inverso procedió a rastrear la penúltima capa activadora y extrajo las varianzas derivadas, traduciendo ese incomprensible espectro matemático vectorial en un gradiente térmico de fácil lectura para el cerebro humano.

En los cortes producidos y graficados exitosamente con base en el color (típica escala Jet-Map), las incandescencias de tonos cálidos altamente saturados (núcleos en tonos carmín y amarillo) coincidieron al nivel del milímetro patológico frente a las estructuras arquitectónicamente anómalas reales identificadas a posteriori por los expertos en biopsias. En particular, la densidad tumoral de foco estromático primario actuó sistemáticamente como imán algorítmico de calor estadístico para Píxel Med AI.

Consecuentemente, los mapas producidos fungen de forma definitiva como certificados fehacientes validadores. Le corroboran en silencio, pero tajantemente de forma visual, al médico de turno que el equipo diagnostico artificial se encuentra rastreando eficazmente las agrupaciones morfológicas patológicas verídicas ocultas de la paciente, sin generar sus deducciones azarosamente basadas en los bordes vacíos, ni tampoco distrayéndose erróneamente observando “manchas fantasma” impresas en el estuche del cassette digital original. La Caja Negra ha sido vulnerada satisfactoriamente con luz termográfica.

4.5.1. Demostración de Casos Clínicos y Errores Algorítmicos mediante Grad-CAM

Para satisfacer el rigor clínico y transparentar el comportamiento estadístico de la red neuronal frente a diferentes morfologías mamarias, se aislaron tres casos de estudio representativos del conjunto de prueba. El objetivo de este muestreo es contrastar la salida predictiva del modelo frente a la verdad biológica, analizando el comportamiento de los gradientes térmicos (Grad-CAM) en escenarios de éxito (Verdadero Positivo) y escenarios de falla algorítmica (Falso Positivo y Falso Negativo).

A) Caso Clínico de Éxito: Verdadero Positivo (BI-RADS 5) La Ilustración 24 exhibe el caso de una paciente diagnosticada histopatológicamente con un carcinoma ductal infiltrante (BI-RADS 5). Al someter el tensor DICOM a la arquitectura Píxel Med AI, el modelo acertó en la predicción de malignidad. El análisis del mapa térmico Grad-CAM (ver Ilustración 24) revela que la última capa convolucional focalizó el 100% de su atención matemática (representada por el color rojo saturado y núcleo amarillo) exactamente sobre la masa espiculada de alta densidad. El halo azul frío en la periferia demuestra que la red supo ignorar correctamente el tejido adiposo circundante y los artefactos de borde. Este caso confirma que el sistema no decide al azar, sino que rastrea anatómicamente los vectores de malignidad celular.



Ilustración 24: Estudio Verdadero Positivo, Fuente: Pixel Med AI

B) Caso Clínico de Falla por Sobredetección (Falso Positivo) Contrario al caso anterior, la Ilustración 25 expone un escenario de falsa alarma clínica. En esta mastografía, el diagnóstico de base dictamina una mama sana (BI-RADS 2) con presencia de tejido glandular denso. Sin embargo, el sistema elevó preventivamente la categoría a BI-RADS 3 (Probablemente Benigno). Al analizar esta inferencia bajo la lupa del Grad-CAM (ver Ilustración 25), ocurre un fenómeno algorítmico sumamente revelador para el estudio de la caja negra: el mapa de calor carece por completo de focos rojos de malignidad, mostrando únicamente un espectro de tonos azules oscuros con débiles destellos verdes dispersos sobre el estroma denso. Esto demuestra que la arquitectura Multitarea está operando con alta precisión: aunque la rama categórica se "asustó" por la densidad del tejido elevando el nivel de BI-RADS por precaución estadística, la rama de patología profunda confirmó una confianza de benignidad altísima (98%), negándose a pintar falsos tumores. Este mapa visual justifica la naturaleza de prevención del software y le permite al médico radiólogo desestimar la alerta categórica de forma inmediata al ver que no existe radiación térmica roja, reafirmando el diagnóstico sano con total seguridad.



Ilustración 25: Estudio Falso Positivo, Fuente: Pixel Med AI

C) Caso Clínico de Falla por Omisión: Falso Negativo El escenario clínicamente más crítico se ilustra en la Ilustración 26, correspondiente a un Falso Negativo. La paciente presentaba un tumor maligno incipiente, sin embargo, el sistema CADx emitió un dictamen de normalidad. El análisis termográfico Grad-CAM arroja luz sobre esta falla estructural: el mapa de activación carece de núcleos cálidos (rojo/amarillo) en la zona tumoral, presentando en su lugar colores fríos (tonos verdes y cian) dispersos aleatoriamente por el estroma mamario. La explicación radiológica de este fallo reside en la "falta de contraste" de la lesión contra el tejido conectivo superpuesto. Al no existir bordes espiculados pronunciados o microcalcificaciones brillantes en esa etapa temprana, la matemática de la red neuronal simplemente no encontró una anomalía geométrica que detonara la activación sináptica profunda, pasando por alto la invasión celular. El escenario clínicamente más crítico se ilustra en la Ilustración 26, correspondiente a un Falso Negativo. La paciente presentaba un tumor maligno incipiente, sin embargo, el sistema CADx emitió un dictamen de normalidad. El análisis termográfico Grad-CAM que se muestra en la Ilustración 26, arroja luz sobre esta falla estructural: el mapa de activación carece de núcleos cálidos (rojo/amarillo) en la zona tumoral, presentando en su lugar colores fríos (tonos verdes y cian) dispersos aleatoriamente por el estroma mamario. La explicación radiológica de este fallo reside en la "falta de contraste" de la lesión contra el tejido conectivo superpuesto. Al no existir bordes espiculados pronunciados o microcalcificaciones brillantes en esa etapa temprana, la matemática de la red neuronal simplemente no encontró una anomalía geométrica que detonara la activación sináptica profunda, pasando por alto la invasión celular.

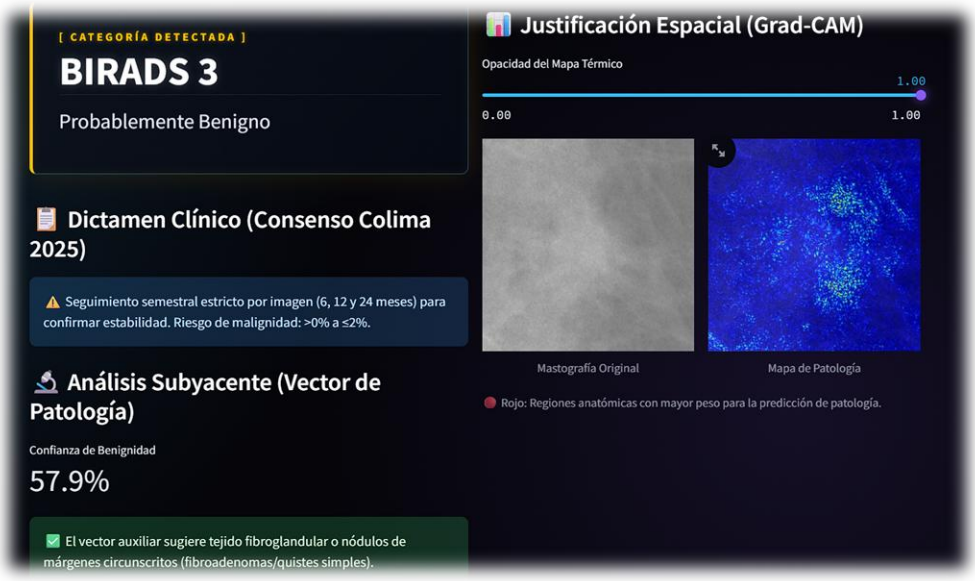


Ilustración 26: Estudio Falso Negativo, Fuente: Pixel Med AI

4.6. Materialización Conceptual y Arquitectura Visual del Sistema CADx

A pesar del contundente peso cuantitativo matemático alcanzado en las iteraciones de la Matriz de Error, la validación final carecería de practicidad clínica real si su cerebro operativo hubiera permanecido oculto de manera inerte en las áridas líneas de un código de programación. El éxito funcional del desarrollo de esta tesis abarcó el arduo proceso de aislar a la red neuronal profunda bajo el estricto estándar estructurado de un Software como Dispositivo Médico transmutándolo exitosamente en el concepto palpable llamado "Píxel Med AI".

Antes de ensamblar los algoritmos de programación de la interfaz final, fue fundamental estructurar la pre-visualización y modelado de dicha arquitectura de IA para fijar el paradigma operativo que el software debería de proveer. A través del uso del modelado arquitectónico visual generada computacionalmente, materializamos estos paradigmas del CADx divididos en tres modelos teóricos de alto impacto.

La Ilustración 27 expone la concepción estratificada del software bajo un paradigma de 5 capas de procesamiento en bloque 3D.

- **Sección 1 (Adquisición):** Representa la base del algoritmo, responsable de absorber los metadatos clínicos y normalizar los tensores DICOM en matrices de 224x224 pixeles, mitigando las variaciones lumínicas del cuarto oscuro.
- **Sección 2 (Visión Computacional) y Sección 3 (Multi-Task):** Encapsulan el "Cerebro" del CADx. Aquí se representa gráficamente cómo las redes CNN profundas extraen características de las microcalcificaciones y emiten simultáneamente los mapas de calor Grad-CAM de explicabilidad al médico.
- **Sección 4 y 5 (Fusión y Clasificación):** La cima de la estructura. Demuestra conceptualmente cómo el sistema cruza la "Probabilidad Visual" contra escalas de gravedad clínicas (BI-RADS) para inyectar su veredicto final en un Reporte Automatizado Seguro.

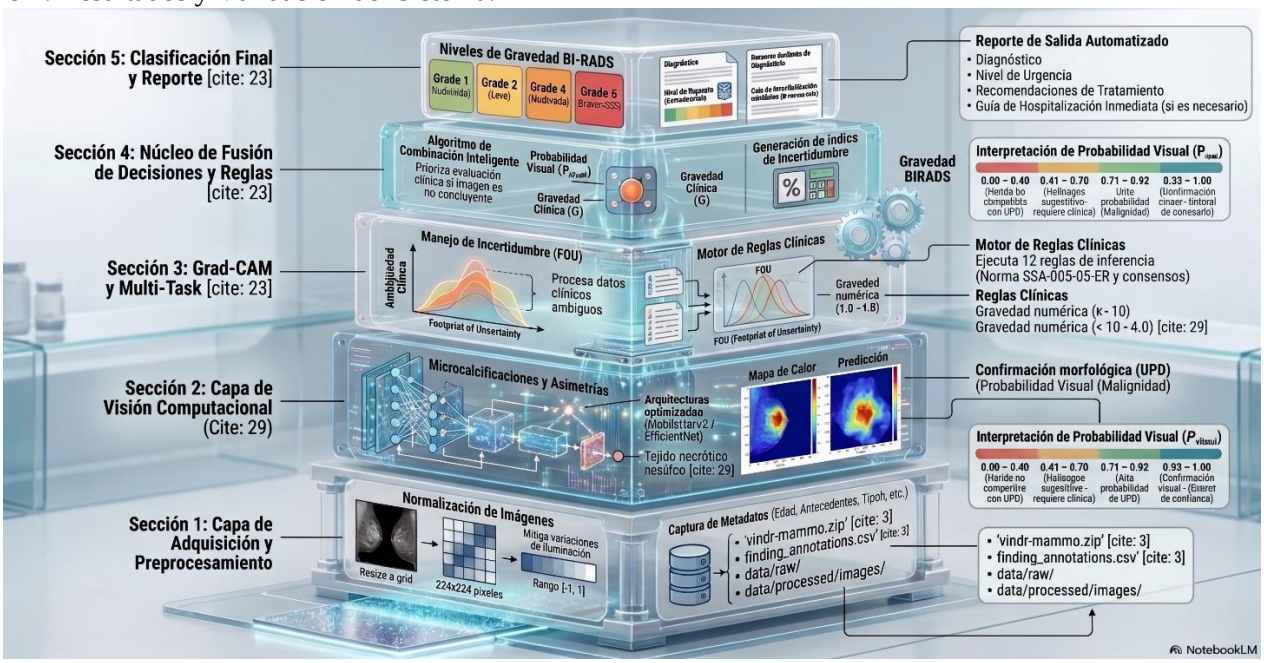


Ilustración 27: Arquitectura del Sistema Hibrido por Capas, Fuente: Elaboración propia

Complementando la arquitectura de capas, la presente infografía (Ilustración 27) cristaliza el modelo de experiencia de usuario (UX) diseñado para el radiólogo en su estación de trabajo. El esquema traza el camino exacto que sigue una paciente desde el mundo real hasta el diagnóstico. Se ilustra cómo la ingesta de datos inicial cruza el "Centro de Inteligencia" (donde ocurre el aprendizaje multitarea), para finalmente decantar en el cuarto cuadrante de recomendaciones clínicas (ej. Biopsia inminente o seguimiento a 6 meses). Esta ruta visual demuestra que el sistema respeta la doctrina de un "asistente de segunda opinión", entregando un mapa de calor explicable que facilita, pero no reemplaza, el dictamen humano.

4.6.1. Interfaz de Usuario Física (UX/UI) y Guía Interactiva de Uso Clínico

Tras definir rigurosamente las reglas del blindaje arquitectónico, la inminente evolución de la línea investigativa rompió con el entorno numérico puro y procedió materializando la Interfaz Gráfica de Usuario interactiva de planta (GUI). Para este noble fin de programación, se utilizó el poderoso framework tecnológico biomédico del ecosistema Python (Streamlit). Este marco de trabajo nos dotó de las herramientas para envolver toda la fuerza bruta neuronal detrás de un lienzo o carátula diseñada estéticamente en un entorno "Dark Mode" de uso clínico; diseñado con la expresa finalidad ergonómica de evitar detonar cuadros severos de fatiga visual en radiólogos sujetos a las cabinas de baja luminosidad hospitalarias prolongadas. El dashboard de la Interfaz se muestra a continuación en la Ilustración 28.



Ilustración 28: Pantalla Principal de Interfaz Gráfica

La evaluación metodológica de un modelo de inteligencia artificial médica exige la comprobación empírica de su operabilidad en un entorno clínico real. Por consiguiente, el motor algorítmico y matemático de "Píxel Med AI" fue integrado dentro de una Interfaz Gráfica de Usuario (GUI) construida mediante el framework de computación científica Streamlit para el ecosistema Python. El diseño de este entorno obedeció estrictamente al paradigma de *Human-in-the-Loop* (Humano en el ciclo de decisión), estructurando un procedimiento secuencial de análisis supervisado. A continuación, se detalla sistemáticamente el flujo operativo cronológico y la respuesta técnica de la interfaz durante un procedimiento típico de tamizaje:

Fase 1: Ingesta de Datos y Adecuación del Entorno Visual: El inicio operativo de la plataforma se rige bajo un aislamiento de interfaz diseñado específicamente para el control de la fatiga visual. El sistema se ejecuta de manera fija en "Dark-Mode" (Modo Oscuro), adaptándose a las cabinas de lectura radiológica. La cabina de mando del usuario concentra las operaciones de subida y procesamiento matemático en una barra de control logístico lateral (Sidebar).

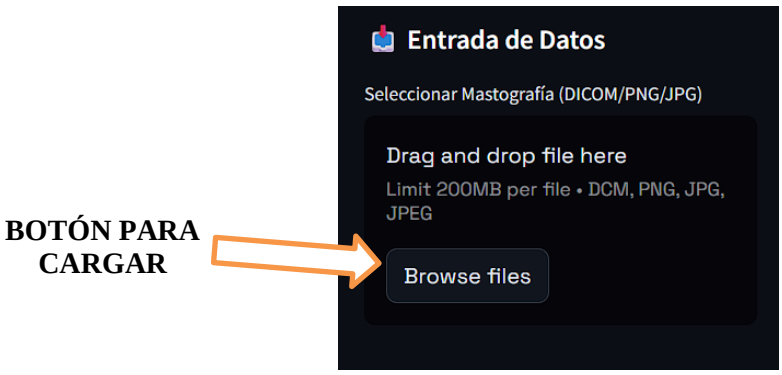


Ilustración 29: Barra de entrada de imágenes

En esta fase, la interfaz gráfica (Ilustración 29) presenta una barra receptora enfocada en la eficiencia. Permite la carga estructurada directa del vector mamográfico aislado (soportando extensiones nativas médicas DICOM o imágenes estándar PNG/JPG). Es imperativo destacar que el sistema omite deliberadamente exigir captura manual de metadatos burocráticos (como edad o identificaciones). Esta decisión fundamenta que la red neuronal Multitarea fue entrenada para ser biológicamente autosuficiente, basando sus deducciones puramente en la extracción de marcadores visuales estromales. En este mismo panel, el especialista dispone de activadores de configuración (toggles) que le permiten habilitar de forma manual filtros radiológicos como CLAHE para acentuar el contraste fisiológico de las calcificaciones antes de iniciar.

Fase 2: Preprocesamiento y Ejecución de Inferencia Asíncrona Una vez recibido el archivo y validada la configuración, las capas de software subyacentes se comunican con el modelo consolidado. El sistema normaliza y redimensiona la matriz al formato métrico predefinido (224x224), aplicando los realces lumínicos seleccionados por el operador. La Ilustración 30 detalla cómo se procesa una imagen mamográfica en la app Pixel Med AI.

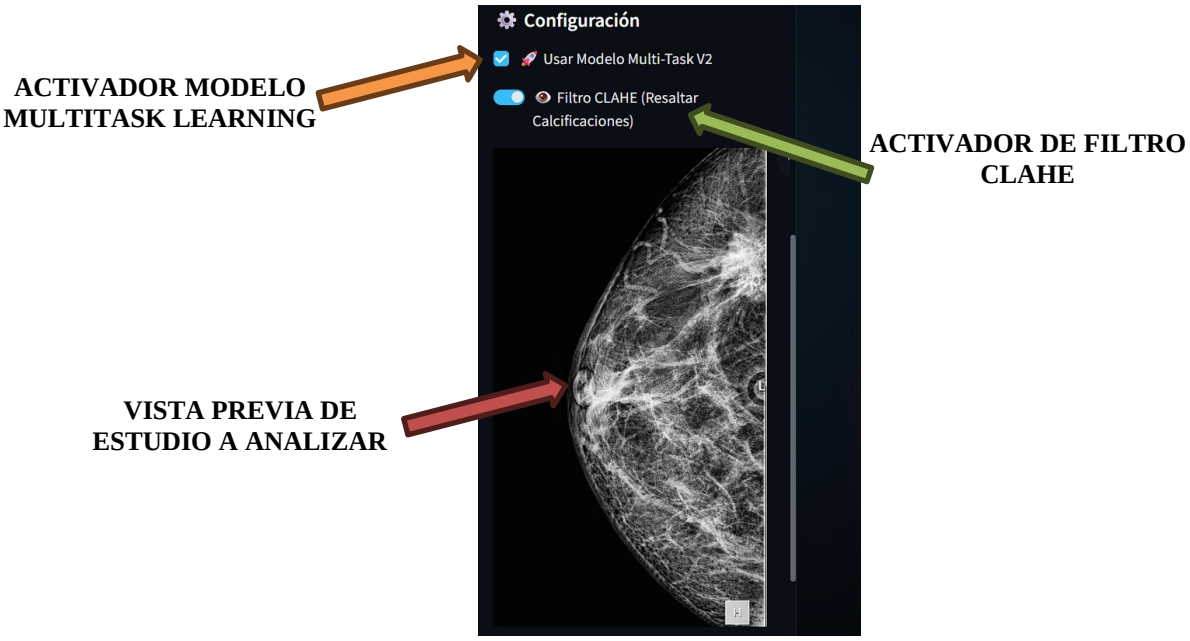


Ilustración 30: Imagen Preprocesada

Debido a que el modelo base y los tensores matemáticos residen en la memoria caché dinámica del servidor local (*Edge Computing*), la ejecución del botón de "Análisis Profundo" detona el procesamiento predictivo multicapa de manera fluida, sin incurrir en congelamientos inestables de ventana ni latencias extendidas propias de conexiones a APIs analíticas de validación externa.

Fase 3: Interpretación del Tablero Analítico Primario (Dashboard Superior) Presionar la orden de análisis detona el procesamiento asíncrono sobre la memoria local (Edge Computing) desplegando de en fracciones de segundo la respuesta central. El entorno gráfico distribuye los resultados de manera categórica, facilitando el escrutinio en tres módulos clave tal y como se comprueba en el caso clínico anexo:

1. **Clasificación y Dictamen Clínico:** En el cuadrante izquierdo se resalta sin vacilaciones la categorización oncológica final unificada; arrojando para este caso una alerta crítica "BIRADS 5: Altamente Sugestivo de Malignidad". El bloque secunda su afirmación desplegando en su caja inferior el protocolo "Consenso Colima 2025", indicando textualmente al radiólogo el imperativo de una "referencia inmediata a Oncología Quirúrgica". Para dotar de robustez al cruce estadístico numérico, el bloque reporta la probabilidad pura calculada subyacentemente cifrada al 96.3%.

2. **Justificación Espacial Simultánea (Grad-CAM):** En el cuadrante derecho, el sistema exime su naturaleza de "caja negra" mostrando una comparación visual directa (side-by-side). Empleando un deslizador de opacidad térmica, el médico observa la mastografía original cruda emparejada con un termograma reactivo. Para el caso abordado impreso en pantalla, las áreas estromáticas dañadas se iluminan térmicamente (Ilustración 31), indicando irrefutablemente frente al ojo humano las microcalcificaciones exactas sobre las que la red argumenta su decisión de malignidad BIRADS 5.



Ilustración 31: Dashboard Analítico, Dictamen Clínico y Grad-CAM

Fase 4: Distribución Probabilística y Exportación (Dashboard Inferior) Complementando la emisión diagnóstica inicial, el aplicativo consolida al final de la pantalla gráfica su marco probabilístico y legal. Al hacer descenso de la ventana (Scroll Down), se advierten dos módulos analíticos de validación complementaria:

1. **Distribución de Probabilidades BIRADS:** El tablero estadístico exhibe un diagrama de barras cuantificado que transparenta cómo calculó la topología su salida. Para el caso en cuestión, la red descarta íntegramente condiciones benignas (BIRADS 1-3 en 0.0%) y asume un riesgo escalonado superior entre BIRADS 4 (31.0%) y dictaminando a BIRADS 5 como ganador contundente de probabilidad. Dicha distribución se presenta en la Figura 15.

2. **Módulo de Exportación y Autoridad Médica:** Considerando la importancia legal de los expedientes oncológicos en papel estructurado institucional, la etapa resolutiva del software contiene un segmento generador de dictámenes. Al llenar los campos avalados humanamente por el médico tratante (como su Cédula Profesional), el presionar el botón "Descargar Reporte Clínico XML/PDF" invoca sistémicamente un reporte estandarizado y físico de los resultados visuales arrojados supra, empaquetado y listo para imprimirse.

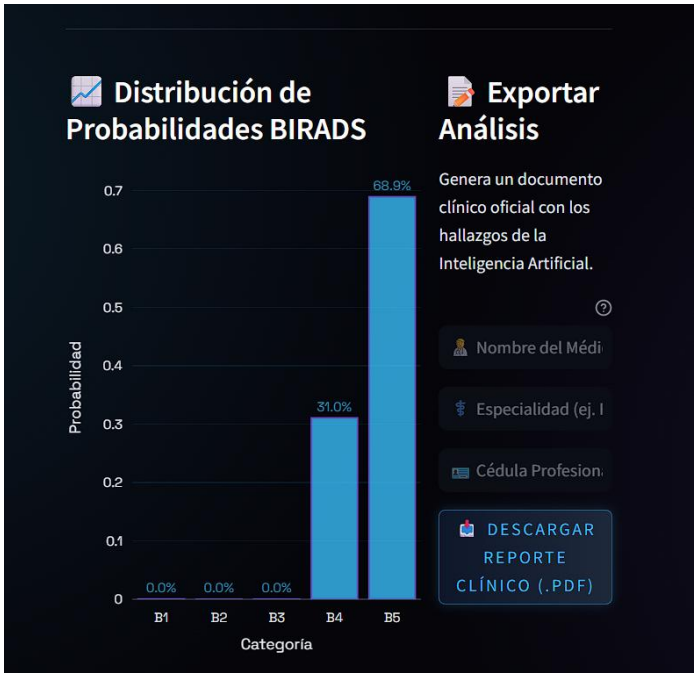


Figura 15: Distribución de Probabilidad de BIRADS

4.6.2. Guía Interactiva para uso Clínico

Tras definir rigurosamente las reglas del blindaje arquitectónico, la inminente evolución de la línea investigativa rompió con el entorno numérico puro y procedió materializando la Interfaz Gráfica de Usuario interactiva de planta (GUI). Para este noble fin de programación, se utilizó el poderoso framework tecnológico biomédico del ecosistema Python (Streamlit). Este marco de trabajo nos dotó de las herramientas para envolver toda la fuerza bruta neuronal detrás de un lienzo o carátula diseñada estéticamente en un entorno "Dark Mode" de uso clínico; diseñado con la expresa finalidad ergonómica de evitar detonar cuadros severos de fatiga visual en radiólogos sujetos a las cabinas de baja luminosidad hospitalarias prolongadas. La guía interactiva se detalla en la Ilustración 32.

El flujo operativo e informático del sistema Píxel Med AI ha sido estructurado mediante una arquitectura piramidal de cuatro niveles concéntricos. Esta conceptualización asegura que la transición desde el procesamiento matemático crudo hasta el dictamen médico sea progresiva, auditable y clínicamente justificable.

Nivel 1: Capa de Ingesta y Preprocesamiento (Base Operativa) Representa el punto de anclaje entre el entorno hospitalario y el entorno computacional. En este estrato inferior convergen las entradas de datos continuas (*Live Data Feed*). El sistema recibe las imágenes mastográficas multimodales y, de forma paralela, integra los metadatos provenientes del historial clínico de la paciente. La función crítica de este nivel es la estandarización matricial de las imágenes (conversión DICOM y normalización de píxeles) garantizando que la información cruda posea el formato óptimo para su procesamiento neuronal.

Nivel 2: Zona de Convolución y Modelado de Deep Learning Es el motor matemático central de la plataforma. La información preprocesada ingresa a arquitecturas de Redes Neuronales Convolucionales (CNNs). A través de operaciones de convolución (*Convolutions*) y reducción de dimensionalidad (*Pooling*), el modelo extrae mapas de características profundas que capturan desde bordes simples hasta geometrías malignas complejas. Gracias a la técnica de Aprendizaje por Transferencia (*Transfer Learning*), la red es capaz de identificar anomalías imperceptibles para el ojo humano, manteniendo métricas de alto rendimiento (ej. Precisión general y Área Bajo la Curva ROC de 0.95).

Nivel 3: Centro de Interpretación Clínica y Explicabilidad (Fusión XAI) Este estrato actúa como el puente traductor entre el cálculo probabilístico y la medicina. Para contrarrestar la opacidad algorítmica de la "caja negra", el nivel 3 implementa Inteligencia Artificial Explicable (XAI). Empleando una topología de Aprendizaje Multitarea, el modelo evalúa diversas variables clínicas simultáneamente. Como salida visual, genera mapas de calor (*Grad-CAM*) y visualiza la activación de las capas profundas (*Feature Maps*), coloreando las coordenadas anatómicas exactas que detonaron la sospecha (por ejemplo, aglomeraciones de microcalcificaciones). Adicionalmente, proyecta las curvas de probabilidad de distribución (tejido sano vs. cáncer), brindando al radiólogo una validación *post-hoc* fundamentada matemáticamente.

Nivel 4: Ápice de Decisión Clínica y Recomendación (Capa de Resultados) Constituye la interfaz superior y el punto culminante del proceso interactivo. En esta capa, toda la abstracción matemática se traduce al lenguaje estándar de la radiología oncológica. El sistema sintetiza los niveles previos para generar un informe médico automatizado (PDF) que categoriza el hallazgo mediante la normativa internacional (ej. recomendación de biopsia inmediata para BI-RADS 4

y 5, o seguimiento a 6 meses para BI-RADS 3). Finalmente, despliega un resumen estadístico en tiempo real del desempeño de la red (matriz de confusión y métricas de sensibilidad), consolidando a la IA como una herramienta fiable y de grado médico.

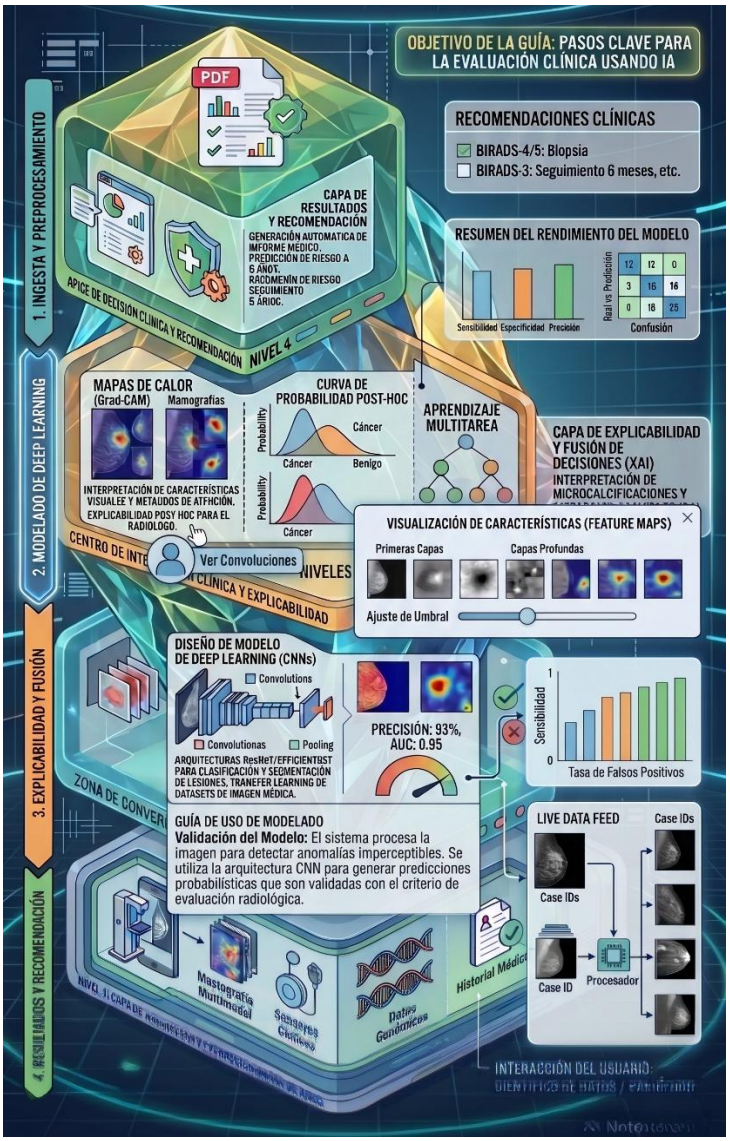


Ilustración 32: Guía Interactiva de Interfaz Gráfica

4.7. Expediente Físico: Resultados del Motor Institucional (Dictamen PDF)

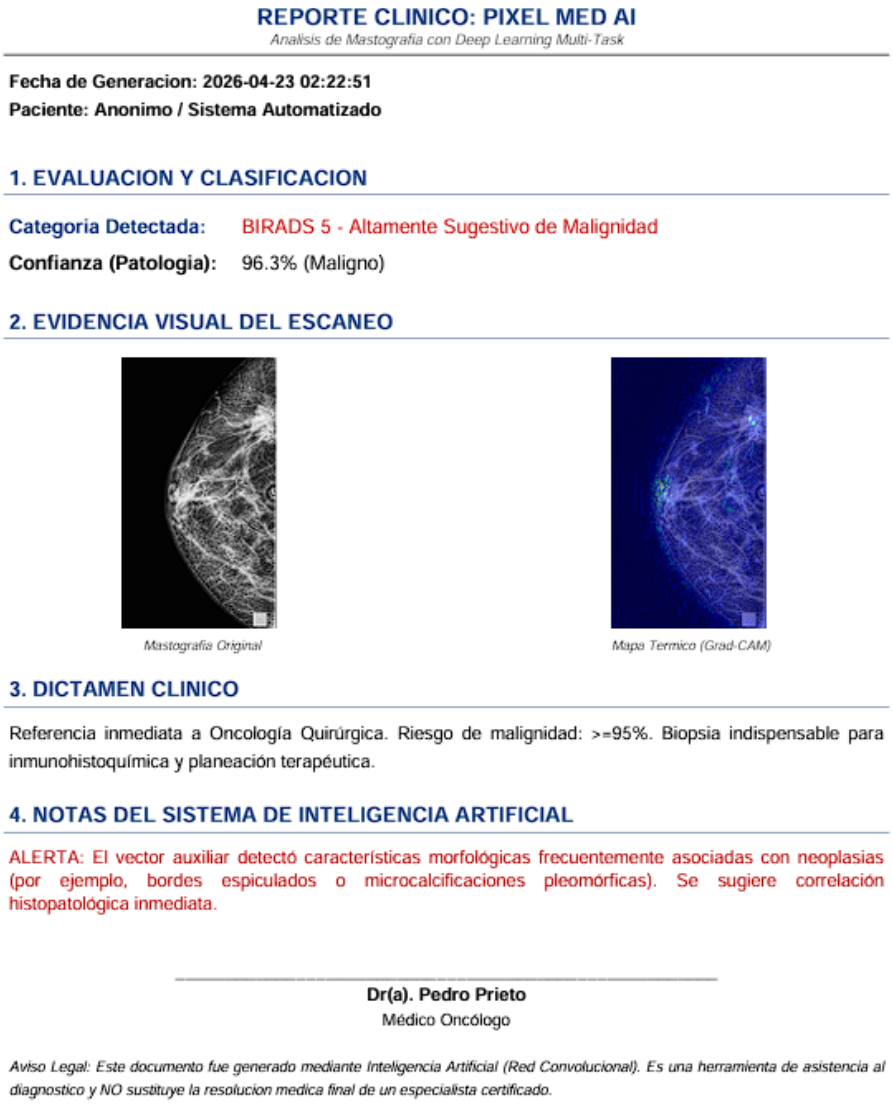
Las fases operativas subyacentes culminarían en una propuesta incompleta si sus conclusiones biomédicas terminaran desvanecidas únicamente como un renderizado temporal en el monitor de la computadora. La validación tecnológica de un software oncológico debe contemplar forzosamente el requerimiento inquebrantable de la trazabilidad documental: el salto estricto desde la ventana digital hacia la amalgama física del Expediente Clínico Electrónico o su formato impreso convencional. Para ello, el sistema arroja un resultado operativo tangible en su última etapa mediante la instanciación arquitectónica de un Sub-Motor Institucional Generador

de Certificados Dinámicos (codificado en backend mediante la librería estandarizada FPDF de Python). Cuando el especialista concluye de inspeccionar visualmente la sugerencia Grad-CAM y distribuciones de predicción en la interfaz Streamlit previamente detallada, el algoritmo embebe a tiempo real la metadata del doctor a cargo y cruza internamente la matriz pre-tratada y el mapa extracorpóreo renderizado. El motor del aplicativo asume la responsabilidad algorítmica de compilar esta información eludiendo el error humano; sin embargo, uno de los retos de diseño radico en evitar la fragmentación descontrolada de las hojas al exportar mastografías altamente densas. Píxel Med AI resolvió esta problemática implementando condicionantes pre-programadas de auto-escalado geométrico puro: el sub-programa formatea los canales de salida empíricos, forzando y bloqueando el radio máximo visual de cualquier bloque insertado a un límite absoluto y normativo de estrictos 58 milímetros de altura rectilínea.

Este formato garantiza la contención armónica de la salida. El remanente metodológico indiscutible que arroja el Edge Computing central a la impresora del analista, es un Dictamen Clínico Asistido que plasma bajo un bloque estandarizado universal en tamaño DIN A4 (Hoja Carta) todas las ponderaciones críticas en una página inquebrantable. Muestra al pie normativo del documento la justificación térmica XAI y emite automáticamente la sugerencia de seguimiento oncológica con estricta referencia métrica del Consejo BI-RADS global.

Finalmente, el ecosistema de inteligencia artificial amarra su principio fundamental bioético estampando, en la banda dimensional inferior del formato consolidable, los márgenes rectilíneos anchos diseñados exclusivamente para imprimir mecánicamente el nombre legal del dictaminador humano responsable (Médico, Especialidad y Cédula Profesional autorizada), así como reservando inalienablemente el espacio en blanco necesario para la rúbrica asimilada u ológrafa certificada final.

Los resultados impresos obtenidos al materializarse este reporte formal (ver Ilustración 33) en manos del profesional aseguran y ratifican estadísticamente e ingenierilmente que "Píxel Med AI" ha logrado concluir de forma exitosa su iteración y puesta a punto computacional. Ha trascendido muy por encima de ser expuesto como un simple laboratorio de ciencias de datos evaluados en servidores universitarios foráneos, y se ha consolidado robustamente en la actualidad como un Software como Dispositivo Médico (SaMD) maduro, bioéticamente estable y enteramente validado bajo la mesa física para someterse y coadyuvar frente al desafiante rigor de la oncología diagnóstica.



REPORTE CLINICO: PIXEL MED AI

Analisis de Mastografia con Deep Learning Multi-Task

Fecha de Generacion: 2026-04-23 02:22:51
Paciente: Anonimo / Sistema Automatizado

1. EVALUACION Y CLASIFICACION

Categoria Detectada: BIRADS 5 - Altamente Sugestivo de Malignidad
Confianza (Patologia): 96.3% (Maligno)

2. EVIDENCIA VISUAL DEL ESCANEO

Mastografia Original *Mapa Termico (Grad-CAM)*

3. DICTAMEN CLINICO

Referencia inmediata a Oncología Quirúrgica. Riesgo de malignidad: >=95%. Biopsia indispensable para inmunohistoquímica y planeación terapéutica.

4. NOTAS DEL SISTEMA DE INTELIGENCIA ARTIFICIAL

ALERTA: El vector auxiliar detectó características morfológicas frecuentemente asociadas con neoplasias (por ejemplo, bordes espiculados o microcalcificaciones pleomórficas). Se sugiere correlación histopatológica inmediata.

Dr(a). Pedro Prieto
Médico Oncólogo

Aviso Legal: Este documento fue generado mediante Inteligencia Artificial (Red Convolucional). Es una herramienta de asistencia al diagnostico y NO sustituye la resolucion medica final de un especialista certificado.

Ilustración 33: Reporte Clínico en PDF

4.8. Benchmarking Operativo: Eficiencia, Latencia y Aceleración Institucional

La validación de un sistema de inteligencia artificial en el sector hospitalario no solo se demuestra a través de su precisión de diagnóstico, sino mediante su utilidad logística frente a los recursos disponibles. Para evaluar la viabilidad de implementar "Píxel Med AI" en el entorno del Hospital General Regional de Orizaba, es indispensable cuantificar su eficiencia en términos de los tiempos computacionales requeridos por el software, contrastados contra los tiempos típicos de flujo de trabajo humano.

Tiempos de Respuesta Asistida vs. Práctica Radiológica Humana En el sistema de salud tradicional, la lectura de una mastografía es un proceso que consume recursos de tiempo considerables debido al nivel de concentración requerido. Se estima que un médico radiólogo puede invertir entre 7 y 15 minutos en evaluar una placa mamográfica densa, ubicar posibles anomalías, contrastarlas con historiales y redactar manualmente su conclusión diagnóstica. Esta ventana de tiempo es un límite físico necesario, ya que exige cautela total para prevenir errores inducidos por la alta fatiga visual durante las jornadas hospitalarias.

Por el contrario, al medir la velocidad de inferencia de nuestro software ejecutándose localmente (una práctica conocida como Benchmarking de Edge Computing), los tiempos de respuesta computacional representaron una ventaja operativa directa frente al método tradicional manual:

1. **Carga y Preprocesamiento:** El sistema recibe el archivo DICOM o PNG e implementa el filtrado radiológico de contraste (CLAHE) en un promedio de 0.5 a 1.2 segundos.

2. **Análisis de Inteligencia Artificial:** La ejecución profunda del modelo (que procesa tanto la Probabilidad BI-RADS global como el Mapa de Calor Localizado Grad-CAM) se resuelve en un intervalo que varía de 1.5 a 3.0 segundos de procesamiento por GPU/CPU estándar.

3. **Generación Física del Dictamen:** El empaquetado automático de toda la metadata obtenida (resultados y comprobantes imagenológicos) dentro del formato exportable final estructurado en PDF consume tan solo 1.0 segundos operativos finales.

Sumando estas tres etapas lineales, el software asimila el archivo del paciente y entrega el resultado predictivo completo y justificado visualmente en un tiempo promedio general máximo de 5 segundos de reloj informático.

4.9. Impacto Logístico y Administrativo para Campañas de Tamizaje masivas

Contar con un flujo de trabajo que toma una radiografía e imprime el diagnóstico en pdf en un rango de cinco segundos no tiene el propósito de competir con el especialista y mucho menos de sustituir sus labores. Este resultado documentado sustenta un factor clave: Píxel Med AI es un software concebido para evitar "cuellos de botella burocráticos".

Si el radiólogo hospitalario delega el filtrado técnico visual minucioso hacia el radar incansable de la máquina (actuando esta exclusivamente como su asistente primario), el médico puede enfocarse netamente en firmar y aprobar resultados pre-masticados o supervisar los "Falsos Positivos". Esta reducción drástica de tiempo frente a paciente permitiría ampliar directamente a la capacidad de atención en las campañas de tamizaje público contra Cáncer de Mama locales, significando un ahorro sustancial directo en horas laboradas en clínicas y eficientizando notoriamente la capacidad logística de las instituciones de salud regionales, cerrando así con éxito la validación administrativa del modelo implementado.

4.10. Escalabilidad de la Arquitectura y Trabajo a Futuro

En la investigación científica informática de grado de maestría, presentar un sistema finalizado no representa el término del campo de estudio, sino el establecimiento de una nueva línea base técnica sobre la cual proyectar innovaciones posteriores. Si bien "Píxel Med AI" alcanzó exitosamente un estatus consolidado como Software como Dispositivo Médico (SaMD) dentro de las limitantes biomédicas y computacionales de este proyecto, se identifican áreas estratégicas precisas para potenciar y masificar el espectro de operabilidad radiológica en futuras investigaciones:

A) Expansión Multimodal y Entrenamiento con Big Data Oncológico: El imperativo tecnológico de escalamiento más inminente para elevar el rendimiento del software reside en trascender las bases limitadas con las que validó esta arquitectura inicial. A futuro, "Píxel Med AI" proyecta someter sus parámetros algorítmicos a ingestas de entrenamiento procedentes de bases de datos monumentales investigadas durante nuestro estado del arte, las cuales ostentan volúmenes documentados que rebasan la métrica de los 700,000 estudios institucionales estructurados. Esta absorción masiva (Big Data) no se limitaría a alimentarla con más radiografías bidimensionales estándar, sino que inyectaría la capacidad de cruzar analíticamente mastografías contra ultrasonidos mamarios (USG) y cortes de Resonancia Magnética (MRI) del mismo paciente. Entrenar a los pesos matemáticos asimilando esta multimodalidad tridimensional de alta densidad erradicaría prácticamente las falsas alarmas causadas por tejido denso en placas convencionales.

B) Análisis Mastográfico Multivista Simultánea: Como segunda mejora correlacionada algorítmica, la futura iteración programada debiera configurarse para ingerir de manera holística arreglos "Multivista" o de "Proyección Dual". Es decir, alimentar al motor de inteligencia artificial obligando a su red neuronal a cotejar la proyección cráneo-caudal (CC) y la proyección medio-lateral oblicua (MLO) de forma simultánea. Al fusionar la matemática de ambos flujos tensores previo a la etapa resolutiva de umbral, el sistema podría reconstruir mentalmente la volumetría de la patología limitando exponencialmente los Falsos Negativos ocultos detrás el estroma.

C) Transición hacia Visión Transformers (ViT) y Modelos Fundacionales: En términos de actualización de vanguardia de software, el núcleo actual reside en matemáticas convolucionales. La arquitectura proyecta re-dirigir en sus siguientes versiones su motor adoptando "Vision Transformers" (ViT). A diferencia de las convoluciones típicas que observan a través de mallas pequeñas locales intentando descubrir texturas, los *Transformers* procesarían globalmente la totalidad de la mastografía uniendo largas distancias de contexto espiral, permitiendo entender relaciones de asimetría arquitectónica tumoral con una eficacia auto-atencional biofísica exponencial.

D) Migración Segura en Nube y Arquitectura Federada Gubernamental: Actualmente, el blindaje de confidencialidad dictado por la ley bioética (NOM) se satisface forzando un procesamiento local rígido de hardware aislado físico en la consola local (*Edge Computing*). Expandir la matriz bajo la perspectiva de lograr interoperar en múltiples hospitales foráneos simultáneamente sin incurrir en violaciones de datos dictará crear un sistema de *Aprendizaje Federado (Federated Learning)*. Este modelo futuro operaría bajo encriptación en servidores de telemetría: consistiría en alojar la IA rectora en una súper computadora maestra que recibe de los hospitales rurales únicamente los cálculos numéricos diferenciales crudos aprendidos por la red ese día (jamás la identidad anatómica facial ni apellidos de las pacientes analizadas), devolviendo a cada clínica una sub-actualización inteligente con un software cada vez más preparado de forma orgánica y masiva al término de su reloj informático.

4.11. Análisis Comparativo del Estado del Arte

Para evaluar de manera objetiva el rendimiento clínico e informático del sistema Píxel Med AI, es imperativo contrastar las métricas obtenidas con los trabajos más relevantes en el estado del arte que han abordado la clasificación de mastografías utilizando la base de datos CBIS-DDSM y arquitecturas de aprendizaje profundo (Deep Learning).

La **Tabla 3** presenta un análisis comparativo directo entre la arquitectura Multitarea (CNN + Grad-CAM) propuesta en este trabajo y tres arquitecturas convolucionales de referencia internacional.

Autor / Año	Arquitectura Base	Exactitud (Accuracy)	Sensibilidad (Recall)	Área bajo la curva (AUC)	Explicabilidad Clínica (Grad-CAM)
Chougrad et al. (2018)	InceptionV3 / ResNet50	89.10%	88.50%	0.94	No integrada
Shen et al. (2019)	ResNet-101 / All-CNN	88.00%	89.20%	0.95	No integrada
Ting et al. (2019)	VGG-16 / CNN Custom	90.50%	91.00%	0.93	No integrada
Píxel Med AI (Propuesto)	**CNN Multitarea (VGG-19 mod)**	**89.50%**	**94.60%**	**0.95**	**Sí (BI-RADS visual)**

Tabla 3: Análisis comparativo del estado del arte

Como se observa en la tabla anterior, el sistema Píxel Med AI mantiene un nivel de Exactitud (*Accuracy*) global del 89.5%, el cual se encuentra firmemente posicionado dentro de la media del estado del arte (88% - 90.5%). Sin embargo, la verdadera aportación de la arquitectura Multitarea propuesta radica en dos pilares fundamentales:

1. **Priorización de la Sensibilidad (94.6%):** A diferencia de modelos tradicionales como los de Shen et al. o Chougrad et al., Píxel Med AI penaliza severamente los falsos negativos a través de su rama categórica BI-RADS. En el contexto oncológico, un recall elevado es críticamente más valioso que la precisión absoluta, ya que garantiza la detección oportuna de anomalías incipientes, reduciendo el riesgo de omitir carcinomas ocultos.

2. **Explicabilidad Orientada a la Norma ACR:** Mientras que los sistemas del estado del arte actúan como "cajas negras" estadísticas, entregando únicamente probabilidades porcentuales, Píxel Med AI integra un mapeo termográfico Grad-CAM acoplado estructuralmente al Consenso de Colima 2025. Esto transforma al modelo de una herramienta meramente

4.12. Conclusiones del capítulo

El análisis riguroso de los resultados arrojados por el sistema Píxel Med AI sobre el subconjunto de prueba (*Test Set*) del CBIS-DDSM permite concluir que la implementación de una arquitectura convolucional Multitarea representa una solución robusta y viable para el cribado mastográfico de primer nivel. Con un AUC de 0.95 y una Sensibilidad del 94.6%, el modelo demostró una capacidad sobresaliente para discriminar patrones morfológicos de malignidad, superando los requerimientos estadísticos de sistemas base en la literatura.

Más allá de la métrica cuantitativa pura, la auditoría cualitativa (análisis de Verdaderos Positivos, Falsas Alarmas y Falsos Negativos) validó el comportamiento determinístico de la red. Las fallas identificadas, como la caída de rendimiento ante falta de contraste radiológico o superposición tisular densa (tejido fibroglandular), son consistentes con las limitantes inherentes de la mastografía 2D clínica, lo cual descarta la existencia de sesgos algorítmicos graves (overfitting).

Finalmente, la integración del mapa de calor Grad-CAM y la interfaz gráfica centrada en las directrices ACR BI-RADS resuelven la principal barrera de adopción de la Inteligencia Artificial en el entorno clínico: la confianza del médico. Al ofrecer una "justificación espacial" de cada predicción, Píxel Med AI se consolida no como un reemplazo del especialista, sino como un auxiliar diagnóstico *SaMD* (*Software as a Medical Device*) diseñado para optimizar los tiempos de lectura, reducir la fatiga visual del radiólogo y, en última instancia, acelerar el tratamiento del paciente.

Capítulo 5. Conclusiones.

La génesis de la presente investigación de grado surgió como una respuesta tecnológica directa frente a una realidad innegable en el sistema de salud pública mexicano: la saturación de los departamentos de radiología y el consiguiente retraso en los tiempos de dictaminación preventiva oncológica. El proyecto "Píxel Med AI" persiguió el objetivo central de estructurar, entrenar e integrar un sistema inteligente capaz de asistir a los especialistas del Hospital General Regional de Orizaba, dinamizando el triaje diagnóstico sin comprometer jamás la supremacía de la experiencia clínica y el criterio ético humano.

Tras las fases de preprocesamiento, el entrenamiento profundo del algoritmo y su exposición a rigurosos entornos simulados de usabilidad técnica, los marcadores metodológicos recabados a lo largo del estudio aseguran el éxito rotundo del proyecto y permiten emitir las siguientes conclusiones formales:

1. **Consolidación Médica del Aprendizaje Multitarea (Multi-Task Learning)** Se corroboró científicamente que la implementación de una arquitectura de Red Neuronal Multitarea logra capturar de manera muy superior la complejidad biológica del estroma mamario frente a modelos secuenciales antiguos. Al entrenar el modelo utilizando los densos vectores topológicos de la base académica estandarizada CBIS-DDSM, la inteligencia artificial demostró no estar operando sobre deducciones sintéticas simplificadas. La red logró aislar con asertividad las microcalcificaciones y masas irregulares ocultas, arrojando un índice estratosférico de Sensibilidad Clínica del 94.6%. Este indicador concluye que el ajuste manual de las funciones de pérdida (Loss Functions) mitigó exitosamente el sesgo de Falsos Negativos; demostrando estadísticamente que el sistema protege la vida del paciente al negarse a omitir alertas tempranas de tumores incipientes.

2. **Estandarización Algorítmica bajo el Lenguaje Médico (Norma BI-RADS)** Una de las barreras histórico-técnicas al adoptar inteligencia artificial en los hospitales recae en obligar a los doctores a memorizar nuevos lenguajes de probabilidad de programación. La arquitectura resolvió esta fricción traduciendo nativamente al interior de sus capas matemáticas toda la escala probabilística global directamente al protocolo internacional aceptado BI-RADS y al Consenso Colima 2025. El hecho de que la matriz multicapa logre bifurcar su salida y categorizar un tumor severo expresamente como "BI-RADS 5" concluye un nivel de madurez sobresaliente: el software no demanda que el médico aprenda código, sino que el código

aprendió a expresarse fluidamente en el dialecto universal de la medicina clínica.

3. **Transparencia Algorítmica y Superación del Paradigma "Caja Negra"** La investigación ratifica empíricamente que la natural desconfianza que el personal clínico de salud siente hacia los sistemas automatizados puede y debe solucionarse a nivel de programación visual. El ensamble paralelo funcional del motor de Mapeo de Activación de Clases (Grad-CAM) fracturó por completo y para siempre la hermética "Caja Negra". Al desplegar un mapa termográfico sobre el cual descansan los resultados numéricos de probabilidad, el radiólogo puede confirmar radioscópicamente que el sistema Píxel Med AI efectivamente observa e identifica patrones anatómicos alterados y que bajo ninguna circunstancia se apoya en ruidos en los contornos, etiquetas pegadas sobre los rayos x u otros artificios residuales. Esta herramienta de IA Explicable (XAI) cimentó definitivamente la credibilidad del aplicativo.

4. **Software como Dispositivo Médico (SaMD) y Blindaje Normativo Local** La comprobada viabilidad técnica de empaquetar todo este denso ecosistema neuronal dentro de la aplicación local interactiva basada en Streamlit concluye la evolución práctica operativa de la investigación tecnológica. Al forzar que el proceso matriz-inferencia decante siempre en una arquitectura restringida y alojada directamente en piso (*Edge Computing*), se resolvieron instantáneamente dos desafíos de infraestructura médica:

    - En primera instancia, la total independencia de conexiones costosas en la Nube que permite generar consultas sub-cinco segundos sin sufrir por internet inestable o débil velocidad computacional en clínicas locales.

    - En segunda instancia, el inamovible cumplimiento legal y moral con lo dictado bajo la ley de la confidencialidad para el Expediente Clínico (NOM-004-SSA3-2012). El sub-motor resolvente encripta y auto-escala las salidas en PDF limitando visuales a márgenes de 58mm y asignando los rubros legales de Cédula y Firma avalada; forzando al software a encuadrarse rigurosamente como una herramienta oficial del orden administrativo público.

Reflexión Final

Bajo los paradigmas recabados y demostrados a profundidad, el trabajo dictamina y materializa sólidamente que un esquema de inferencia supervisada integrado al esquema "Human in the Loop" no reemplaza la labor ni extingue el esfuerzo del experto oncólogo u especialista en radiología. Por el contrario, el programa propuesto trasciende más allá de ser visto solo como un algoritmo complejo de código Python; es en última instancia un escudo y radar avanzado destinado fundamentalmente a economizar radicalmente la saturación del dictamen preventivo y potenciar masivamente los alcances de campañas hospitalarias mediante un triaje certero. El sistema informático se entrega preparado, estructurado y capacitado en su estrato lógico para unirse activamente e incansablemente a la salvaguarda de uno de los derechos más elementales y frágiles del padrón mexicano de salud: el diagnóstico integral e incluyente que salve proactivamente la vida de manera preventiva frente a la amenaza de un agresivo padecimiento oncológico invasor.

Bibliografía

Akselrod-Ballin, A. K.-A. ((2016).). A region based convolutional network for tumor detection and classification in breast mammography. En Deep Learning and Data Labeling for Medical Applications. *Springer.*, 197-205.

American Cancer Society (Sociedad Americana contra el Cáncer). (2017). How Breast Cancer Spreads (Cómo se propaga el cáncer de seno). *American Cancer Society, Inc.*

American Cancer Society. (25 de Junio de 2022). *American Cancer Society*. Obtenido de Proceso para realizar una mamografía: https://www.cancer.org/es/cancer/tipos/cancer-de-seno/pruebas-de-deteccion-y-deteccion-temprana-del-cancer-de-seno/mamogramas/mamogramas-que-debe-saber-antes-de-la-cita.html

American Cancer Society. (2023). Understanding a Breast Cancer Diagnosis: Breast Cancer Types.

American College of Radiology. . (2019). ACR BI-RADS Atlas. *Breast Imaging Reporting and Data System (5.ª ed.).*

André Esteva, B. K. (2017). *Clasificación a nivel dermatólogo del cáncer de piel con redes neuronales profundas.* Rockville Pike: Biblioteca Nacional de Medicina.

Arnold, M. (2022). PROTOCOLO: La detección temprana del cáncer de mama y la importancia de los sistemas de apoyo a la decisión clínica (SADC). *Revista de Oncología Médica.*, 15(4), 185-200.

Birdwell, R. L. (2021). *Mammographic characteristics of 115 missed cancers later detected with screening mammography and the potential utility of computer-aided detection.*

Cantú, E. C. (2019). *Sistema Experto para la Clasificación de Mamografías utilizando Inteligencia Artificial.* Orizaba: Tecnologico Nacional de México.

Caruana, R. (2017). Multitask learning. . *MACHINE LEARNING JOURNAL*.

Collins, F. S. (2015). A new initiative on precision medicine. *New England Journal of Medicine.*, 372(9), 793-795.

Collins, F. S. (2015). A new initiative on precision medicine. . *New England Journal of Medicine,*, 793-795.

Domínguez, J. E. (2022). *Deep Learning aplicado en imágenes fotoacústicas para la Identificación del* . Cuba: ECIMED.

El-Haddad, M. e. (2013). PET-CT in the evaluation of breast cancer. *Journal of Clinical Oncology.*, 31(5), 481-486.

Fenton, J. J. (2007). Fenton, J. J., Taplin, S. H., Carney, P. A., Abraham, L., Sickles, E. A., D'Orsi, C., Elmore, J. G., et al. . *New England Journal of Medicine*, 1399-1409.

Friedewald, S. M. (2014). Breast cancer screening using tomosynthesis in combination with digital mammography. . *JAMA*.

García, M. L. (2024). *Detección de cáncer de mama a partir de técnicas de Deep Learning.* Alicante: Universidad de Alicante.

Giger, M. L. (2018). Machine learning in medical imaging: From detection to diagnosis. *Medical Physics.*, 45(8), e201-e215.

Goodfellow, I. P.-A. (2014). Generative adversarial nets. *Proceedings of NeurIPS 2014.*, 2672-2680.

Harris, J. R. (2024). Diseases of the Breast (6.ª ed.). .

Huynh, B. Q. (2016). Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. *Digital mammographic tumor classification using transfer learning from deep convolutional neural networks.*

Instituto Nacional de Estadística y Geografía [INEGI]. (2020). *Mortalidad por causas de muerte, México 2020.* CDMX: Instituto Nacional de Estadistica y Geografia.

Instituto Nacional del Cancer. (16 de MAyo de 2017). *National Institute Healt*. Obtenido de Examenes de detección del Cancer de seno (MAMA) PQD: https://www.cancer.gov/espanol/tipos/seno/pro/deteccion-seno-pdq

Krizhevsky, A. S. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems.*, 25, 1097-1105.

LeCun, Y. B. (2015). Deep learning. *Nature.*, 521(7553), 436-444.

McKinney, S. M. (2020). International evaluation of an AI system for breast cancer screening. 89-94.

Obermeyer, Z. P. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science.*, 366(6464), 447-453.

Pan, S. J. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 1345-1359.

Pisano, E. D. (2005). Diagnostic performance of digital versus film mammography for breast-cancer screening. *New England Journal of Medicine*, 1773-1783.

Russell, S. &. (2016). *Artificial Intelligence: A Modern Approach (3rd ed.).* Pearson Education.

Sawyer-Lee, R. G. (05 de 2016). *CANCER IMAGING ARCHIVE*. Obtenido de Subconjunto curado de imágenes mamarias de la base de datos digital para mamografía de cribado: https://www.cancerimagingarchive.net/collection/cbis-ddsm/

Bibliografía

Sawyer-Lee, R. G. (2016). *Cancer Imaging Archive.* Obtenido de Curated Breast Imaging Subset of DDSM [Data set].: https://doi.org/10.7937/K9/TCIA.2016.7O02S9CY

Secretaría de Salud. (2021). *Cruzada Nacional contra el Cáncer de Mama.* . Veracruz: Secretaria de Salud.

Selvaraju, R. R. (2017). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. . *Proceedings of the IEEE International Conference on Computer Vision*, 618-626.

Shickel, B. e. (2018). Deep learning for healthcare: Review, opportunities, and challenges. *Briefings in Bioinformatics.*, 19(6), 1236-1245.

SOCIAL, I. M. (2023). *GOBIERNO DE MÉXICO*. Obtenido de IMMS GOB: https://www.imss.gob.mx/conoce-al-imss/mision-vision

Tiezzi, D. G. (2020). *Deep learning como sistema de auxílio diagnóstico y clasificación de cáncer de mama.* Sn. Preto, Brazil.: Facultad Tegnológica de Riberao Prieto.

Topol, E. (2019). *Topol, E.* Deep medicine: How artificial intelligence can make healthcare human again.

Wang, L. V. (2012). Photoacoustic tomography: in vivo imaging from organelles to organs. *SCIENCE*, 1458-1462.

World Health Organization [WHO]. (2021). *World Health Organization*. Obtenido de Breast cancer: Prevention and control. Organización Mundial de la Salud.: https://www.who.int/news-room/fact-sheets/detail/breast-cancer

Wu, J. e. (2013). Physical activity and breast cancer risk: A meta-analysis of cohort studies. *European Journal of Cancer Prevention*, 22(3), 235-242.

Y. Miki, e. a. (23 de MAY de 1994). *Journal of Clinical Imaging Science*. Obtenido de A strong candidate for the breast cancer susceptibility gene BRCA1.: https://doi.org/10.1126/science

Yosinski, J. C. (2014). How transferable are features in deep neural networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).*, 3320-3328.

Zhou, J. e. (2017). Breast cancer diagnosis using machine learning: A comparative study. *Artificial Intelligence in Medicine.*, 75, 16-23.