

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Electricidad y Computación

Segmentación y clasificación automática de meningiomas cerebrales en imágenes
de resonancia magnética utilizando Inteligencia Artificial

TECH-374

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Ciencias de la Computación

Presentado por:

Nicolás Andrés Plaza Iñiguez

Diego Javier Reyes Medranda

Guayaquil - Ecuador

Año: 2024

Dedicatoria

El presente proyecto lo dedicamos a nuestros padres, Denise Iñiguez, Vicente Plaza, Sonia Medranda y Angel Reyes; y hermanos, Vicente Plaza y André Reyes, por su amor y apoyo incondicional a lo largo de toda nuestra experiencia académica. A ustedes, que han celebrado nuestros logros y brindado consuelo en los momentos difíciles, dedicamos con profunda gratitud este trabajo.

Agradecimientos

Queremos agradecer en primer lugar a dios a Dios, por ser nuestro guía y parte indispensable de nuestras vidas.

A nuestras familias por su apoyo, paciencia y cariño que ha sido un soporte fundamental en nuestro día a día.

A nuestros profesores/as y compañeros/as, por compartir sus conocimientos y experiencias. Sus valiosos consejos y críticas han sido esenciales para mejorar nuestro trabajo.

En especial a los profesores Enrique Peláez, Francis Loayza y Luis Eduardo Mendoza. Por guiarnos y brindarnos su apoyo y conocimientos durante esta última etapa universitaria.

Declaración Expresa

Nosotros, Nicolás Andrés Plaza Iñiguez y Diego Javier Reyes Medranda, acordamos y reconocemos que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por nosotros durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me/nos corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi/nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique a los autores que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 20 de septiembre de 2024.

Nicolás Andrés Plaza Iñiguez

Diego Javier Reyes Medranda

Evaluadores

Luis Eduardo Mendoza Morales, Ph.D.

Profesor de Materia

Colon Enrique Peláez Jarrín, Ph.D.

Tutor de proyecto

Resumen

La detección precisa y temprana del grado de malignidad de los meningiomas es un desafío para los doctores, debido a que su ubicación y tamaño dificulta su diagnóstico. Los avances en Inteligencia Artificial han permitido mejorar la precisión en la clasificación del grado del tumor, en imágenes de resonancia magnética, obteniendo resultados más precisos y en menor tiempo. Así el médico puede tomar una mejor decisión para el tratamiento del paciente. El presente proyecto propone el desarrollo de un algoritmo de aprendizaje automático a partir de la segmentación del meningioma. Se realizó un estudio comparativo de diferentes modelos de clasificación y diferentes algoritmos de selección de características del meningioma. Los modelos basados en árboles alcanzaron mejores resultados, utilizando características de 3 conjuntos: forma tridimensional, matriz de grises y primer orden. Extra Trees resultó ser el mejor, con un puntaje F1 de 94%, seguido por Random Forest con 92%. Se integraron los modelos de segmentación y clasificación a una aplicación web, que permite el análisis de imágenes de resonancia magnética para clasificar el tumor. Los hallazgos obtenidos sugieren una guía para futuros estudios que busquen clasificar el grado de malignidad de meningiomas a partir de otros enfoques diferentes al análisis de sus características.

Palabras Clave: Características radiómicas, Aprendizaje Automático, Aprendizaje Profundo, Tumor cerebral, Diagnóstico

Abstract

Accurate and early detection of the malignancy grade of meningiomas is a challenge for doctors, due to their location and size making diagnosis difficult. Advances in Artificial Intelligence have enabled improvements in the accuracy in tumor grade classification, in magnetic resonance images, obtaining more accurate results in less time. Thus, the doctor can make a better decision for the patient's treatment. The present project proposes the development of a machine learning algorithm, based on the previously segmented meningioma. A comparative study was conducted on different classification models and different meningioma feature selection algorithms. Tree-based models achieved better results, using features from 3 sets: three-dimensional shape, gray matrix and first order. Extra Trees being the best with an F1 score of 94%, followed by Random Forest with 92%. The segmentation and classification models were integrated into a web application, which allows the analysis of magnetic resonance images to classify the tumor. The results obtained suggest a guide for future studies aimed at classifying the malignancy grade of meningiomas using approaches other than the analysis of their characteristics.

Keywords: *Radiomic Features, Machine Learning, Deep Learning, Brain Tumor, Diagnosis.*

Índice general

Resumen	I
<i>Abstract</i>	II
Índice general	III
Abreviaturas	VI
Índice de figuras	VIII
Índice de tablas	IX
Capítulo 1	1
1. Introducción	2
1.1 Descripción del Problema	2
1.2 Justificación del Problema	3
1.3 Objetivos	4
1.3.1 Objetivo general	4
1.3.2 Objetivos específicos	4
1.4 Marco teórico	5
1.4.1 Meningiomas: Información, diagnóstico y tratamiento	5
1.4.2 Avances de las técnicas de IA en segmentación y clasificación de tumores	6
2. Metodología	10
2.1 Exploración inicial acerca del problema	10
2.2 Decisiones referentes a las técnicas de IA y bases de datos para el análisis del problema y su solución.	10
2.2.1 Base de datos	11

2.2.2	Arquitecturas para modelos de segmentación	12
2.2.3	Extracción de características radiómicas a partir de la segmentación.....	12
2.3	Requerimientos.....	12
2.3.1	Usuarios de la aplicación.....	13
2.3.2	Requerimientos funcionales	13
2.3.3	Requerimientos no funcionales	14
2.4	Alcance y limitaciones de la solución	15
2.5	Riesgos y beneficios de la solución.....	16
2.5.1	Riesgos	16
2.5.2	Beneficios.....	16
2.6	Prototipado.....	16
2.6.1	Flujo de ventanas.....	17
2.7	Evaluación	22
2.8	Diseño de solución.....	23
2.8.1	Modelo de segmentación.....	23
2.8.2	Modelo de clasificación.....	24
2.8.3	Métricas de evaluación usadas en modelos de IA	24
2.8.4	Arquitectura (Modelo de “4+1” Vistas de Kruchten)	25
2.8.5	Diseño de bases de datos.....	30
2.9	Plan de Implementación	31
Capítulo 3	32

3.	Resultados y análisis	33
3.1	Desarrollo	33
3.1.1	Modelo de segmentación.....	33
3.1.2	Modelo de clasificación.....	36
3.1.3	Interfaz de la aplicación	39
3.2	Resultados.....	39
3.2.1	Interfaz de la aplicación	39
3.3	Validación del proyecto con el cliente.....	43
3.4	Análisis de costos	43
Capítulo 4.....		45
4.	Conclusiones y recomendaciones.....	46
4.1	Conclusiones.....	46
4.2	Recomendaciones	46
Referencias.....		49
Apéndice A.....		57
Apéndice B.....		59
Apéndice C.....		66
Apéndice D.....		66

Abreviaturas

ASNR	American Society of Neuroradiology
BraTS	Brain Tumor Segmentation Challenge
CEDIA	Corporación Ecuatoriana para el Desarrollo de la Investigación y la Academia
CBTRUS	Central Brain Tumor Registry of the United States
CNN	Convolutional Neural Network
DICE	Metrica de similitud entre conjuntos
DL	Deep Learning
ESPOL	Escuela Superior Politécnica del Litoral
ET	Enhancing Tumor
FIMCP	Facultad de Ingeniería Mecánica y Ciencias de la Producción
FLAIR	Fluid Attenuated Inversion Recovery
GTR	Gross Total Resection
IA	Inteligencia Artificial
IRM	Imágenes Por Resonancia Magnética
MSE	Mean Squared Error
ML	Machine Learning
NTC	Non-Enhancing Tumor Core
LNB	Laboratorio de Bioingeniería y Neuroimagen
OMS	Organización Mundial de la Salud
SFNH	Surrounding non-enhancing FLAIR hyperintensity
STR	Subtotal Resection
T1C	T1 post-contraste
T1N	T1 pre-contraste
T2F	T2-FLAIR

T2W T2 ponderada

U-NET CNN en forma de U

Índice de figuras

Figura 1 Vista de base de datos de usuarios registrados en la aplicación web (I).....	17
Figura 2 Vista de base de datos de usuarios registrados en la aplicación web (II)	18
Figura 3 Vista de diagnósticos en base de datos (I)	18
Figura 4 Vista de diagnósticos en base de datos (II).....	19
Figura 5 Vista de inicio de sesión (Médico).....	20
Figura 6 Vista de aplicación de diagnóstico médico (I).....	20
Figura 7 Vista de aplicación de diagnóstico médico (II)	21
Figura 8 Vista de descarga de diagnóstico ejecutado.....	21
Figura 9 Vista de perfil de usuario médico e historial de diagnósticos (I).....	22
Figura 10 Vista de perfil de usuario médico e historial de diagnósticos (II)	22
Figura 11 Modelo de “4+1” vistas Kruchten	25
Figura 12 Diagrama de Estados de la aplicación web.....	28
Figura 13 Diagrama de Componentes de la aplicación web	29
Figura 14 Diagrama de Despliegue de la aplicación web	30
Figura 15 Diagrama de Entidad Relación de la aplicación web.....	30
Figura 16 Valores DICE promedio a lo largo de las 100 épocas (Modelo t1c)	34
Figura 17 Valores DICE para las etiquetas de BraTS2023 a lo largo de las 100 épocas (Modelo t1c).....	35
Figura 18 Vista de aplicación actualizada.....	40
Figura 19 Vista de base de datos de usuarios actualizada.....	41
Figura 20 Vista de actualización de usuario actualizada.....	41
Figura 21 Vista de diagnósticos en base de datos actualizada	42
Figura 22 Vista de actualización de diagnóstico actualizada.....	42
Figura 23 Vista de actualización de información de perfil de administrador (I)	59

Figura 24 Vista de actualización de información de perfil de administrador (II)	60
Figura 25 Vista de creación de usuario (I)	60
Figura 26 Vista de creación de usuario (II).....	61
Figura 27 Vista de creación de usuario (III).....	61
Figura 28 Vista de creación de usuario (IV)	62
Figura 29 Vista de actualización de usuario (I).....	62
Figura 30 Vista de actualización de usuario (II)	63
Figura 31 Vista de actualización de usuario (III).....	63
Figura 32 Vista de actualización de usuario (IV).....	64
Figura 33 Vista de eliminación de usuario (I).....	64
Figura 34 Vista de eliminación de usuario (II).....	65
Figura 35 Vista de actualización de usuario (III).....	65

Índice de tablas

Tabla 1 Historias de Usuario de Médico y Administrador.....	26
Tabla 2 Criterios de aceptación para la historia de usuario MED-05	26
Tabla 3 Criterios de aceptación para la historia de usuario ADMIN-02.....	27
Tabla 4 Cronograma de actividades para el desarrollo	31
Tabla 5 Modelos de Machine Learning y algoritmos de selección utilizados durante entrenamiento.....	37
Tabla 6 Resultados de mejores modelos de Machine Learning y algoritmos de selección utilizados	37
Tabla 7 Mejores características seleccionadas por el mejor modelo.....	38
Tabla 8 Detalle de costos.....	44

Capítulo 1

1. Introducción

1.1 Descripción del Problema

Los meningiomas son tumores originados en las meninges cerebrales, membranas que recubren el cerebro y la médula espinal, y representan un 40.8% de los tumores del Sistema Nervioso Central (SNC) [1]. De acuerdo con la Organización Mundial de la Salud (OMS), se reconoce a los meningiomas como un solo tipo de tumor con 15 subtipos clasificados en 3 grados: benignos (grado I), atípicos (grado II) y anaplásicos o malignos (grado III), cuya distribución es aproximada en 80%, 18% y 2%, respectivamente [1], [2].

Aunque la gran mayoría de tumores son benignos y no presentan síntomas, la presencia de meningiomas atípicos, y en menor medida los anaplásicos, suponen un riesgo para la salud del paciente. La ubicación, tamaño y tasa de crecimiento de los meningiomas puede alterar las funciones cerebrales y ocasionar efectos neurológicos adversos en función de la parte del tejido cerebral presionada, ocasionando diversos síntomas tales como, dolores de cabeza, convulsiones, problemas de visión, problemas de coordinación, etc. Por lo que la detección temprana, la identificación del grado de este y el tratamiento oportuno, es vital para salvaguardar la vida del paciente.

El uso de Imágenes por Resonancia Magnética (IRM) representa un estándar para analizar el tumor [3]. Sin embargo, la segmentación y clasificación del meningioma usando IRM presenta desafíos que pueden afectar la precisión del diagnóstico e introducir variabilidad en la planificación del tratamiento como la necesidad de personal capacitado, la presencia o no de síntomas, la similitud con otras lesiones intracraneales y subjetividad en la interpretación de las imágenes neurológicas.

Por otro lado, los avances en investigación en relación con las técnicas de Inteligencia Artificial (IA), tales como, visión por computadora junto con el procesamiento de IRM, han contribuido a una mejora en la precisión de la detección y diagnóstico de enfermedades [4].

Adicionalmente, dichos avances han permitido identificar, segmentar y clasificar lesiones en imágenes médicas, obteniendo resultados con una precisión que rivaliza o supera a los especialistas humanos en muchos casos [5], [6]. De esta forma, se podrían realizar intervenciones más oportunas y precisas para el tratamiento de los meningiomas en los pacientes, obteniendo resultados más favorables para ellos.

Con el presente proyecto se busca superar el problema que supone la detección precisa y rápida de los meningiomas en las imágenes médicas a través del uso técnicas de IA, implementando un sistema integrado que permita la identificación y segmentación precisa y rápida del meningioma con el fin de analizarlo y clasificarlo en benigno o atípico, proporcionando información oportuna que favorezca la realización de un diagnóstico médico certero. El presente proyecto se realiza a petición del Laboratorio de Bioingeniería y Neuroimagen (LNB) de la Facultad de Ingeniería Mecánica y Ciencias de la Producción (FIMCP), un reconocido laboratorio de la Escuela Superior Politécnica del Litoral (ESPOL), enfocado en el uso de la ingeniería en el campo médico con el fin de encontrar soluciones que mejoren la calidad de vida de las personas.

1.2 Justificación del Problema

La relevancia del presente problema radica en la dificultad inherente que resulta la identificación y detección precisa de los meningiomas, durante el análisis médico en pacientes enfermos. La detección de estos tumores presenta limitaciones en cuanto a su precisión y la intervención humana introduce subjetividad durante los diagnósticos, lo cual afecta en gran medida el tratamiento que debe llevar el paciente, incidiendo directamente en su calidad de vida [7].

El emplear las técnicas de IA en la segmentación y clasificación de los meningiomas, permite obtener resultados de análisis médicos con una eficacia y eficiencia superior [8], [9], [10], [11], [12], [13], [14], brindando información vital a los especialistas, al permitirles tomar

decisiones informadas en torno al tratamiento de los pacientes, como la decisión de cirugía, radioterapia y seguimiento, entre otros, maximizando la eficacia del tratamiento [4], [12].

Asimismo, el brindar diagnósticos más precisos no solo favorece las condiciones de salud para el paciente durante su tratamiento, sino que también permite enfocarse en el cuidado mental de sus familias reduciendo sentimientos negativos como angustia, ansiedad y depresión durante el tratamiento [15], [16].

Por otro lado, el emplear herramientas con modelos de IA para procesos médicos permite conducir a tratamientos más efectivos y menos costosos a largo plazo, lo cual favorece a los pacientes con su situación económica, a la par que favorece a las instituciones médicas al evitar el uso de recursos innecesarios en procedimientos médicos o con tratamientos erróneamente dirigidos, lo cual, a su vez, puede propiciar una mayor inversión para la realización de investigaciones y desarrollo de herramientas basadas en IA aplicadas al campo de la salud.

1.3 Objetivos

1.3.1 Objetivo general

Desarrollar una aplicación web accesible y de fácil uso que, mediante el uso de técnicas de IA, permita la carga y análisis de imágenes de resonancia magnética T1 y FLAIR de manera automática para la segmentación y clasificación de meningiomas.

1.3.2 Objetivos específicos

1. Desarrollar una serie de historias de usuario para determinar los requerimientos esenciales del aplicativo web.
2. Diseñar un componente de preprocesamiento de datos que permita la carga y procesamiento de las IRM.
3. Diseñar un modelo de segmentación usando técnicas de IA para la identificación y el delineamiento del meningioma en las IRM.

4. Diseñar un modelo de clasificación basada en técnicas de IA para la clasificación del meningioma en benigno o atípico.
5. Desarrollar una aplicación web enfocada en la segmentación y clasificación de meningiomas en IRM mediante la integración de los componentes de software y modelos de basados en IA desarrollados.

1.4 Marco teórico

1.4.1 Meningiomas: Información, diagnóstico y tratamiento

Los meningiomas son descritos como tumores intracraneales más comunes, representando la tercera parte de los tumores prevalecientes que afectan al SNC [1]. Según estudios realizados por parte del Registro Central de Tumores Cerebrales de Estados Unidos (CBTRUS, por las siglas en inglés de Central Brain Tumor Registry of the United States) entre el 2016 y el 2020, los meningiomas presentaban una incidencia de 9.73 por 100.000 habitantes, predominando en mujeres y en personas de la tercera edad [1].

Originados a partir de las células aracnoides en la superficie interna de la duramadre, la literatura indica que la ocurrencia de éstos se encuentra asociado a diversos factores de riesgo que pueden incrementar su aparición, tales como, la exposición del cráneo a radiaciones ionizantes, obesidad, traumatismos cerebrales, sedentarismo y la presencia hormonal [17], [18], [19]. A su vez, la presencia de síndromes familiares como neurofibromatosis tipo 2, el síndrome de Gorlin, el síndrome de Cowden y mutaciones en genes como el síndrome de predisposición tumoral BAP1, entre otros, los cuales han demostrado incrementar el riesgo de presencia de los meningiomas [17], [18], [20].

La gran mayoría de estos tumores se hallan incidentalmente y son asintomáticos; y en función de su localización, los síntomas pueden ser diversos [21]. Dolor de cabeza debido al aumento de presión intracraneal, problemas de visión y cognición, y cambios de personalidad son síntomas comunes durante el diagnóstico [17], [22]. Entre los métodos más comunes para el

diagnóstico predomina el uso de IRM seguido de tomografías computarizadas, mientras que la histopatología y patología molecular proporcionan información para soportar el diagnóstico [3].

Sin embargo, el diagnóstico de los meningiomas presenta desafíos que pueden incidir enormemente en el tratamiento a seguir, como el diagnóstico diferencial, los subtipos y grados del meningioma, el seguimiento del crecimiento y recurrencia [3]. Entre los métodos de tratamiento de este tumor podemos hallar la observación de forma “esperar y ver”, la resección del tumor mediante cirugía, radioterapia; e inclusive tratamientos con farmacológicos y quimioterapia [18], [23].

Los tratamientos estarán sujetos en base a la presencia de síntomas, en donde se empiece por el uso de la observación para aquellos meningiomas asintomáticos, mientras que para aquellos meningiomas atípicos y anaplásicos con alta presencia de síntomas se empleen métodos más rigurosos como la resección total bruta (GTR, por las siglas en inglés de Gross Total Resection) o resección subtotal (STR, por las siglas en inglés de Subtotal Resection) del tumor si hay un alto riesgo de comprometer las funciones neurológicas del paciente [18].

1.4.2 Avances de las técnicas de IA en segmentación y clasificación de tumores

En el análisis de imágenes médicas, la segmentación es un proceso que analiza cada píxel de la imagen asignándole una etiqueta o clase específica para separar la imagen en “segmentos” [24]. Mientras que en la segmentación se asigna una clase a cada píxel de la imagen, la clasificación asigna la etiqueta o clase a todo el objeto o entidad usada como dato de entrada sea texto, imagen, audio, video, entre otros [25].

En la actualidad, existen herramientas de software que permiten al usuario ejecutar modelos de IA para realizar análisis de IRM. Programas como FreeSurfer, CaPTk, TK-SNAP, Raidionics se encuentran disponibles al público con acceso libre para descargar permitiendo al usuario ejecutar tareas de segmentación y extracción de características de meningiomas de manera automática [26], [27], [28]. Una forma de mejorar la accesibilidad de este software es

utilizando herramientas en línea para el uso de estos modelos de IA, sin incurrir en la descarga e instalación de estas herramientas. Plataformas como BrainChop [29] surgen como una solución de análisis de neuroimágenes basado en la web.

Asimismo, la segmentación y clasificación de meningiomas se ha visto beneficiada gracias al enfoque de extracción de características radiómicas, las cuales, a partir de los tumores segmentados en una IRM junto con algoritmos de ML, extraen diversas características y patrones de la zona de interés como su forma, brillo y textura, brindando información vital para obtener resultados más precisos [14], [30], [31], [32], [33]. Dado su potencial, se han desarrollado herramientas como PyRadiomics, enfocadas en permitir la extracción de manera estandarizada y con una diversidad de características para proveer información más precisa al usuario [34].

De igual forma las IRM de tumores cerebrales son aplicadas en modelos de segmentación de tumores cerebrales basados en Aprendizaje Profundo (DL, por las siglas en inglés de Deep Learning) para detectar posibles enfermedades [35]. Con esas consideraciones, la secuencia T1 y la secuencia de Recuperación de la inversión atenuada de fluido (FLAIR por sus siglas en inglés de Fluid attenuated inversion recovery) de IRM son útiles para el diagnóstico temprano de infecciones cercanas a la meninge [36]. A su vez, el uso de modelos de DL y Redes Neuronales Convolucionales (CNN, por las siglas en inglés de Convolutional Neural Network) puede mejorar las prácticas médicas en el análisis de imágenes, estos modelos han sido evaluados por numerosos estudios como [10], [37], [38] para la segmentación y clasificación de tumores cerebrales.

También existe la posibilidad de utilizar DL con una arquitectura híbrida, lo que extiende las posibilidades para la clasificación y predicción de grados para los meningiomas, lo que demuestra que DL es una tecnología viable para evaluación de meningiomas por parte de los expertos en medicina [39]. Al introducir conceptos como mecanismos de atención o entrada multiescalar a una arquitectura de redes neuronales como la U-NET (denominada así por su

forma de “U”), se puede mejorar el rendimiento de la segmentación de meningiomas, llegando a resultados clínicos relevantes [40].

Capítulo 2

2. Metodología

2.1 Exploración inicial acerca del problema

Para el desarrollo del presente proyecto, el punto de partida fue la realización de reuniones introductorias con el Tutor del Proyecto, Dr. Enrique Peláez, y el Cliente, Dr. Francis Loayza, representante del Laboratorio de Bioingeniería y Neuroimagen (LNB) de la FIMCP de ESPOL. En las reuniones se conoció información acerca de los meningiomas, su procesamiento para segmentarlos y clasificarlos en IRM por medio de técnicas de DL y ML, así como la metodología a seguir para el desarrollo del proyecto.

Asimismo, se acordó realizar reuniones semanales para evaluar el avance del proyecto y se dio paso a la revisión de literatura asociada con los meningiomas y su diagnóstico, para conocer con mayor profundidad sobre las técnicas y herramientas de análisis empleadas.

2.2 Decisiones referentes a las técnicas de IA y bases de datos para el análisis del problema y su solución

Durante la revisión de la literatura se halló que el uso de arquitecturas DL, como la U-Net y sus variaciones, representaban un estándar para la segmentación de meningiomas [12], [40]; mientras que el uso de modelos poco profundos, tales como Random Forest, Regresión Logística, Extra Trees, y otros, eran ampliamente usados para la clasificación del grado de malignidad de los meningiomas [33]. Otros estudios como [38], destacan el uso de arquitecturas CNN para la clasificación de los meningiomas.

Dadas las diferentes consideraciones, se acordó revisar arquitecturas actuales para la segmentación 3D en IRM y explorar diferentes modelos ML para clasificar los meningiomas en las clases grado I o grado II a partir del análisis de las características radiómicas extraídas desde los segmentos. También, se acordó que en base a la calidad de los resultados obtenidos se decidiría si optar por dicho enfoque o explorar arquitecturas DL como la CNN para la

clasificación del meningioma a partir del análisis de las IRM. Asimismo, se acordó realizar la búsqueda de datos públicos disponibles en base de datos de IRM sobre meningiomas para realizarlas pruebas de los modelos de segmentación y clasificación.

2.2.1 Base de datos

Como resultado de la búsqueda, la base de datos se seleccionó la base de datos del “Brain Tumor Segmentation (BraTS) meningioma 2023 challenge” desarrollada por la Sociedad Americana de Neurorradiología (ASNR por sus siglas en inglés de American Society of Neuroradiology) [41].

Dicha base de datos contiene una serie de IRM de diversos sujetos que presentan meningiomas intracraneales recopilados en diversos centros académicos médicos de los Estados Unidos de América [41] junto con información acerca del grado de malignidad del meningioma. Cada sujeto en la base de datos BraTS 2023 posee 4 diferentes secuencias IMR:

- T1 pre-contraste (T1N)
- T1 post-contraste (T1C)
- T2 ponderada (T2W)
- T2 FLAIR (T2F)

La base de datos posee un conjunto de 3 etiquetas asociados a la segmentación y a las diferentes subregiones del meningioma en la IRM [41].

- Tumor potenciado (ET)
- Tumor no potenciado (NTC)
- Hiperintensidad FLAIR circundante sin potenciado (SFNH)

La base de datos cuenta con un total de 1000 sujetos con las 4 secuencias IRM.

2.2.2 Arquitecturas para modelos de segmentación

Para la segmentación de meningiomas en las IRM se utilizó una CNN con arquitectura U-Net 3D para las pruebas iniciales al ser un estándar para problemas de segmentación en objetos 3D. A su vez, se revisaron arquitecturas adicionales como el modelo DeepMedic [42] o el modelo de segmentación CLCI-Net [43].

2.2.3 Extracción de características radiómicas a partir de la segmentación

Para la clasificación de los meningiomas en grado I o grado II, el primer paso fue explorar una serie de librerías o herramientas que permitieran realizar el proceso de extracción de características radiómicas a partir de los segmentos, destacándose paquetes de Python como: PyRadiomics [34] y PyFeats [44]. Tras un análisis referente a las prestaciones de ambos paquetes, se decidió emplear PyRadiomics gracias a los 7 conjuntos de características que permite extraer usando la IRM con la etiqueta de segmentación; y, porque ciertas funciones de PyFeats no se adecuaban al proceso de extracción 3D requerido. A partir de estas clases, se extrajeron 112 características de los 999 sujetos de la base de datos usando la etiqueta ET.

2.3 Requerimientos

Durante las reuniones periódicas con el cliente se procedió a realizar el levantamiento de requerimientos funcionales y no funcionales, enfocados en determinar aquellos aspectos que el cliente considere relevantes y necesarios para el correcto funcionamiento de la solución a la problemática planteada.

El cliente proporcionó una descripción inicial sobre lo que se espera como entregable para resolver el problema, el cual constituye en una aplicación web donde los médicos puedan cargar las IRM de sus pacientes, procesar la IRM cargada e indicar al usuario en que parte de la IRM se encuentra el meningioma identificado y a su vez, proporcionar un análisis que indique si el meningioma era benigno o atípico, con un porcentaje de confiabilidad.

Asimismo, se especificó que debe existir un usuario administrador que permita administrar a los diferentes usuarios médicos que usan la aplicación, permitiendo crear usuarios, activarlos o desactivarlos y actualizar su información. Del mismo modo, se indicó que debería ser posible guardar la información de los diagnósticos realizados y sus observaciones o recomendaciones.

Respecto a los requerimientos no funcionales, se indicó que el sistema debía ser simple y de fácil uso para el personal médico. En este sentido, se destacó el hecho de que la interfaz debía ser simple y de fácil navegación para el usuario, permitiéndole ejecutar los diagnósticos con poca cantidad de clics, y sin elementos visuales que distraigan o no sean relevantes para las labores del médico. Con dichas indicaciones se procedió a redactar los siguientes requerimientos.

2.3.1 Usuarios de la aplicación

Analizando la descripción inicial y conversando con el cliente, se determinó la existencia de 2 usuarios principales para la aplicación desarrollada:

- Médicos autorizados
- Usuarios administradores

Por consiguiente, los médicos deben ser autorizados por el Administrador mediante la creación de un perfil de usuario médico para acceder a la aplicación web.

2.3.2 Requerimientos funcionales

A continuación, se exponen los requerimientos funcionales desarrollados para los diferentes tipos de usuarios del sistema.

2.3.2.1 Médico

- Posibilidad de iniciar sesión en la aplicación web.
- Cargar IRM en la aplicación y posibilidad de poder cargar el archivo nuevamente en caso de error.

- Ejecutar el diagnóstico para visualizar la ubicación del meningioma en la IRM y conocer el grado de este.
- Brindar recomendaciones sobre el diagnóstico resultante a la aplicación.
- Guardar el diagnóstico resultante.
- Visualizar los diagnósticos previos ejecutados.
- Cerrar sesión.

2.3.2.2 Administrador

- Registrar usuarios (médicos u administradores) en la aplicación web.
- Actualizar la información de los distintos usuarios en la aplicación web.
- Visualizar la información de los distintos usuarios en la aplicación web.
- Cambiar el estatus de los usuarios de la aplicación web.
- Visualizar los diagnósticos ejecutados por los usuarios médicos.
- Guardar los diagnósticos ejecutados por los usuarios médicos.
- Cargar IRM en la aplicación y posibilidad de poder cargar el archivo nuevamente.
- Ejecutar el diagnóstico para visualizar la ubicación del meningioma en la IRM y conocer el grado de este.
- Iniciar sesión en la aplicación web para acceder al portal de administrador.
- Cerrar sesión de la aplicación web.

Para un mayor detalle de los requerimientos, en formato de historias de usuario, véase la sección “Diseño de la solución”.

2.3.3 *Requerimientos no funcionales*

- El sistema debe ofrecer tiempos de respuesta cortos (en pocos segundos).
- El sistema debe proporcionar a los usuarios una interfaz de fácil uso que permita obtener el resultado del análisis en no más de 2 clicks.

- El sistema debe ser simple, enfocado en permitir su uso y no sobrecargar a los usuarios médicos con opciones que no le son relevantes.
- Uso de autenticación y autorización para restringir el acceso de modo que solo personal médico autorizado pueda hacer uso de la aplicación.
- El sistema solo empleará y guardará información relacionada a las predicciones del modelo de clasificación. Asimismo, el usuario médico debe dar su consentimiento para acceder a la aplicación web y poder utilizarla.

2.4 Alcance y limitaciones de la solución

Basados en los requerimientos levantados, el alcance del sistema fue establecido, abarcando el desarrollo de una aplicación web, donde usando un usuario y contraseña los médicos puedan cargar IRM de sus pacientes para procesarlas y generar un análisis relacionado con el grado de malignidad del meningioma pudiendo guardar el resultado y dar su retroalimentación.

De igual importancia, el sistema incorpora herramientas para que los usuarios administradores puedan autorizar y gestionar el acceso a la web por parte de los usuarios médicos y de su información, junto con la de los diagnósticos ejecutados.

Respecto a las limitaciones de la solución, al ser desarrollada como aplicación web, se requerirá con antelación una conexión a Internet estable para poder acceder. A su vez, esta aplicación no fue diseñada para uso público; sólo para personal médico que previamente haya sido autorizado. Por otro lado, se requerirá de antemano que los médicos adquieran la autorización de sus pacientes para el uso de sus datos, puesto que las IRM que empleen serán procesadas y empleadas por la aplicación.

2.5 Riesgos y beneficios de la solución

2.5.1 Riesgos

Entre los riesgos presentados por el uso de la aplicación, se contempla la posibilidad de que la información de los usuarios médicos y de sus pacientes pueda ser vulnerada por medio de un ataque cibernéticos si no se cuenta con medidas de seguridad como encriptación de datos o protocolos de comunicación seguros. A su vez, dado que el sistema recibe archivos de IRM para ser almacenados, la integridad del sistema puede verse vulnerada si uno de estos archivos está infectado con un programa maligno o virus. Se recomienda evitar problemas que afecten a la integridad del sistema y sus datos.

2.5.2 Beneficios

- Identificación precisa de la presencia del meningioma en la IRM mediante el delineamiento de los contornos.
- Clasificación precisa del grado de malignidad del meningioma.
- Ejecución de un diagnóstico eficaz y temprano que brinde información vital para una la planificación adecuada del tratamiento de los pacientes.
- Posibilidad de conducir el tratamiento del meningioma con un menor costo a largo plazo al conocer los límites y grado del tumor.
- Mejora en la calidad de vida del paciente al conocer de manera eficaz su condición médica.
- Democratización del acceso a diagnósticos de alta calidad.

2.6 Prototipado

Se desarrollaron prototipos de alto nivel para poner implementar las funcionalidades requeridas y realizar las pruebas. Se elaboraron con la herramienta web Figma, gracias a sus

amplias prestaciones. A su vez, se empleó la librería web Gradio para el desarrollo del sistema en Python.

2.6.1 Flujo de ventanas

Las ventanas desarrolladas se enfocaron en representar los requerimientos funcionales levantados para cada uno de los tipos de usuario de la aplicación web. Se presentarán las pantallas de los requerimientos más relevantes, las demás pantallas se adjuntarán al Apéndice B.

2.6.1.1 Administrador

En la vista del administrador se pueden realizar acciones como:

Visualizar los usuarios registrados en la base de datos (ver Figura 1, Figura

- Figura 2).

Visualización de diagnóstico médicos en la base de datos de diagnósticos y permitir su descarga (ver Figura 3,

- Figura 4)

Figura 1

Vista de base de datos de usuarios registrados en la aplicación web (I)

espol johndoe27

Visualizar Base de datos

Usuarios
Diagnósticos

Acción
Seleccione una acción Ir

Se han encontrado: 1 registros

<input type="checkbox"/>	id	username	firstname	lastname	email	cellphone	status	isMedic	isSuperUser	date.join	lastLogin
<input type="checkbox"/>	01	johndoe27	John	Doe	johndoe_test@mail.com	0987654321	Active	No	Yes	04/07/2024	04/07/2024:17:00

Figura 2

Vista de base de datos de usuarios registrados en la aplicación web (II)

Visualizar **Base de datos**

Usuarios
Diagnósticos

Acción
Selecione una acción ^
Ir

Crear
Actualizar
Eliminar

Se han encontrado: 1 registros

<input type="checkbox"/>	id	username	firstn...	lastn...	cellphone	status	isMedic	isSuperUser	dateJoin	lastLogin
<input type="checkbox"/>	01	johndoe27	John	Doe	johndoe_2601@mail.com	0987654321	Active	No	Yes	04/07/2024 17:00

Figura 3

Vista de diagnósticos en base de datos (I)

Visualizar **Base de datos**

Usuarios
Diagnósticos

Acción
Selecione una acción v

Se han encontrado: 1 registros

<input type="checkbox"/>	id	grade1	grade2	observation	userID	imageID
<input type="checkbox"/>	img21	0.97	0.03	Great diagnosis	02	dfjdyfwy78

Figura 4

Vista de diagnósticos en base de datos (II)

Visualizar Base de datos

Usuarios
Diagnósticos

Acción
Descargar

Descargar

Se han encontrado: 1 registros

	id	grade1	grade2	observation	userID	imageID
<input checked="" type="checkbox"/>	sm01	0.97	0.03	Great diagnosis	02	gthfytary7/8

2.6.1.2 Médico

En la vista del usuario médico se pueden realizar acciones como:

Iniciar sesión en la aplicación web (ver

- Figura 5).

Ejecutar un diagnóstico médico en la aplicación (ver Figura 6 y Figura

- Figura 7).
- Descargar el diagnóstico médico ejecutado (ver Figura 8).

Ver la información básica de su perfil y el historial de diagnósticos médicos que el usuario ha ejecutado (ver

- Figura 9 y Figura Figura 10)

Estas acciones también las puede realizar el usuario administrador.

Figura 5

Vista de inicio de sesión (Médico)



espol

Aplicación para segmentación y clasificación de meningiomas

Inicio de sesión

Usuario
janep56

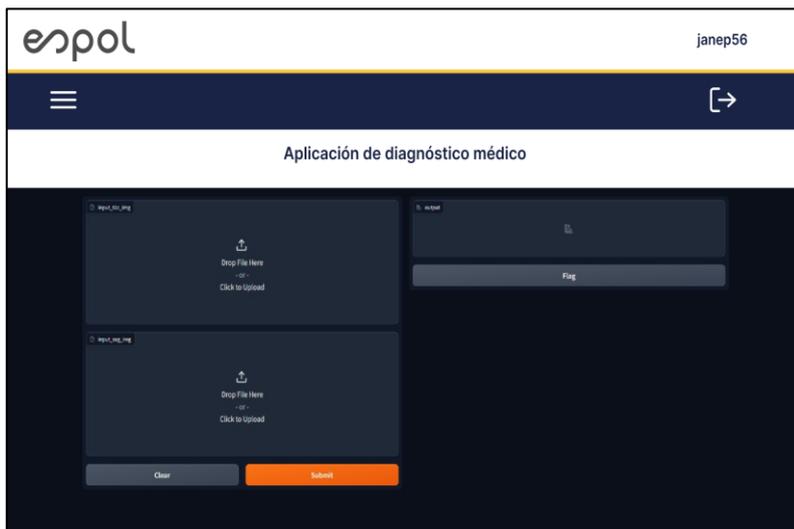
Contraseña

Iniciar sesión

[¿Olvido su contraseña?](#)

Figura 6

Vista de aplicación de diagnóstico médico (I)



espol janep56

Aplicación de diagnóstico médico

Drop File Here
Click to Upload

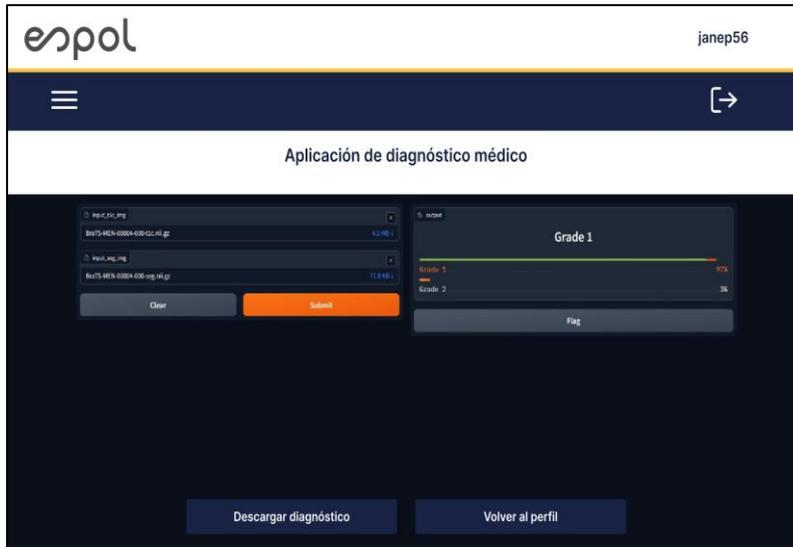
Drop File Here
Click to Upload

Flag

Clear Submit

Figura 7

Vista de aplicación de diagnóstico médico (II)

**Figura 8**

Vista de descarga de diagnóstico ejecutado

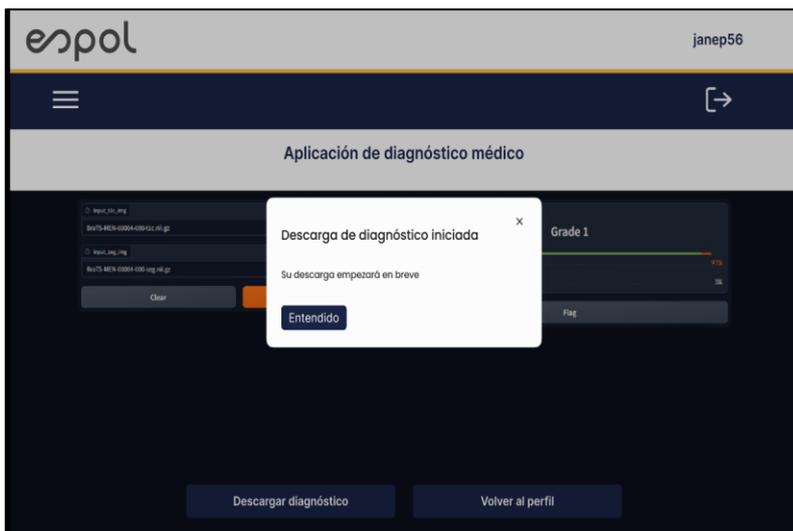


Figura 9

Vista de perfil de usuario médico e historial de diagnósticos (I)



espól janep56

Jane Parker
janep56

Ver información del usuario

Diagnósticos ejecutados

id	grade1	grade2	observation	fecha	
im01	0.97	0.03	Great diagnosis	07/07/2024	Descargar

Figura 10

Vista de perfil de usuario médico e historial de diagnósticos (II)



espól janep56

Información de usuario

Nombre Jane Parker

Username janep56

E-mail janep56@mail.com

Rol Usuario

Teléfono 0987776321

Volver

2.7 Evaluación

Desarrollado el prototipo de alta fidelidad, éste fue presentado y evaluado con el tutor del proyecto y el cliente de manera iterativa para garantizar que este cumpliera con los

requerimientos establecidos. Tras las evaluaciones realizadas, las interfaces presentadas del prototipo para el administrador y el médico cumplieron con las expectativas de lo enunciado en los requerimientos funcionales, aprobándose el prototipo y recibiendo a la par recomendaciones para mejorar la experiencia de los usuarios, principalmente para el médico. Se recomendó ajustar la navegación del médico para que al iniciar sesión sea redirigido a la herramienta para ejecutar el diagnóstico médico, para agilizar la realización del diagnóstico.

A su vez, se indicó que se debían ajustar las etiquetas que brindan información para evitar la confusión y añadir más elementos visuales que brindasen retroalimentación visual al usuario respecto al estado de la aplicación. De igual importancia, para el administrador se recomendó añadir campos adicionales en la base de datos de diagnósticos para brindar información sobre las imágenes resultantes.

Con la retroalimentación recibida se procedió a ajustar elementos del prototipo de alta fidelidad para que cumpliera con las observaciones finales recibidas para la posterior implementación en código con las herramientas de seguridad de datos mencionadas anteriormente.

2.8 Diseño de solución

2.8.1 Modelo de segmentación

- **Segmentador basado en U-Net:** Es una arquitectura caracterizada por su forma de U simétrica que se puede dividir en dos partes, una parte de codificación y otra de decodificación. En la primera parte se transforma el volumen de entrada, mientras que en la decodificación es aumentar las dimensiones espaciales reduciendo el mapa de características. La arquitectura base y sus variantes han sido utilizada para la segmentación de tumores cerebrales, con buenos resultados [45].

- **Segmentador DeepMedic:** Es una arquitectura CNN 3D para la segmentación de lesiones cerebrales, el diseño de la arquitectura es adecuado para procesar volúmenes médicos gracias a su naturaleza 3D. Esta arquitectura ha demostrado un buen rendimiento en competencias en tareas de segmentación de lesiones complejas como tumores cerebrales [46].

2.8.2 *Modelo de clasificación*

Los siguientes algoritmos de clasificación de ML son implementaciones utilizando la librería de Scikit-learn [47], cuyos resultados fueron analizados para escoger el de mejor desempeño.

- **Clasificador aleatorio de bosques (RandomForest en inglés):** Es un meta estimador que ajusta una serie de árboles de decisión en varias submuestras del conjunto de datos. Para mejorar la precisión y mitigar el sobreajuste se utiliza el promedio. Cada árbol de decisión utiliza una estrategia de división óptima.
- **Clasificador de árboles adicionales (Extra-Tree en inglés):** A diferencia de los árboles de decisión clásico, este clasificador separa las muestras en nodos y busca la mejor división posible, por cada característica seleccionada aleatoria se generan divisiones aleatorias y se elige la mejor entre ellas.

2.8.3 *Métricas de evaluación usadas en modelos de IA*

Para la medición de los resultados del modelo de segmentación se empleó el coeficiente de DICE [48] expresado en la ecuación (2.1):

$$DICE = \frac{2 * |A \cap B|}{|A| \cup |B|} \quad (2.1)$$

en donde siendo $|A|$ la cardinalidad del conjunto A , $|B|$ la cardinalidad del conjunto B y $|A \cap B|$ la intersección entre los 2 conjuntos, DICE indica la similitud existente entre 2 pares de

conjuntos y permite determinar cuan similares son las etiquetas de segmentación que predice el modelo y la máscara de segmentación (grado de verdad).

De igual importancia, para medir los resultados del modelo de clasificación se utilizó la métrica del valor F1 [49] detallado en la ecuación (2.2):

$$F1 = \frac{2 * precision * sensibilidad}{precision + sensibilidad} \quad (2.2)$$

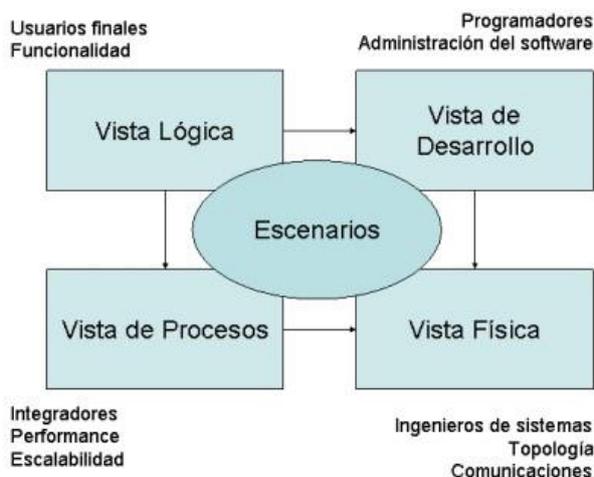
Este valor indica la media armónica entre los valores de precisión y sensibilidad, usada para medir el rendimiento general de un modelo de clasificación.

2.8.4 Arquitectura (Modelo de “4+1” Vistas de Kruchten)

Para el diseño de la solución, se utilizó el modelo de vistas de Kruchten [50] detallado en la Figura 11. Los diagramas presentados en las vistas son diagramas UML del sistema implementado.

Figura 11

Modelo de “4+1” vistas Kruchten. Adaptado de [50]



2.8.4.1 Historias de usuario en la Vista de Escenarios.

Los escenarios son representados como historias de usuario, cada una con un criterio de aceptación. En la Tabla 1 se presenta las dos historias de usuario escogidas para servir como

ejemplo por cada uno de los usuarios del sistema, las demás historias de usuario se encuentran en el Apéndice A.

Tabla 1

Historias de Usuario de Médico y Administrador

Identificador	Rol	Característica/Funcionalidad	Razón/Resultado
MED-05	Como un Médico	Necesito visualizar el grado de malignidad del meningioma	Con la finalidad de obtener información que me ayude a obtener un diagnóstico preciso
ADMIN-02	Como un Administrador	Necesito crear/registrar a los nuevos usuarios (médicos/administradores) en la aplicación web	Con la finalidad de brindar acceso a los a las diferentes herramientas de la aplicación web en función de su rol (médico o administrador)

2.8.4.1.1 Criterios de Aceptación.

1. En la Tabla 2 se presentan los criterios de aceptación para la historia de usuario MED-05:

Visualizar grado de malignidad del meningioma.

Tabla 2

Criterios de aceptación para la historia de usuario MED-05

Criterio de Aceptación	Contexto	Evento	Resultado/Comportamiento esperado
Meningioma clasificado	En caso de que se obtuvo un resultado de la segmentación.	Cuando se termina de procesar la imagen correctamente.	El sistema presenta el resultado de la clasificación con el porcentaje de pertenencia a la clase.
Meningioma no clasificado	En caso de que no se obtuvo un resultado de la segmentación.	Cuando se termina de procesar la imagen correctamente.	El sistema presenta el resultado de la clasificación con el porcentaje de pertenencia a la clase.

2. En la Tabla 3 se presentan los criterios de aceptación para la historia de usuario ADMIN-02: Crear nuevos usuarios en la aplicación web.

Tabla 3

Criterios de aceptación para la historia de usuario ADMIN-02

Criterio de Aceptación	Contexto	Evento	Resultado/Comportamiento esperado
Registro usuario administrador exitoso	En caso de que el administrador haya dado clic al botón "Registrar administrador" y haya llenado correctamente la información del nuevo administrados en el formulario de usuario administrador en la aplicación web	Cuando el administrador de clic en el botón "Crear usuario administrador"	El sistema mostrará una notificación indicando que el nuevo usuario administrador fue creado de manera correcta con los permisos adecuados.
Registro usuario administrador cancelado	En caso de que el administrador haya dado clic al botón "Registrar administrador" y haya llenado incorrectamente la información del nuevo administrador en el formulario de usuario administrador en la aplicación web	Cuando el administrador de clic en el botón "Volver"	El sistema redirigirá a usuario administrador en hacia la página principal del panel de administración.

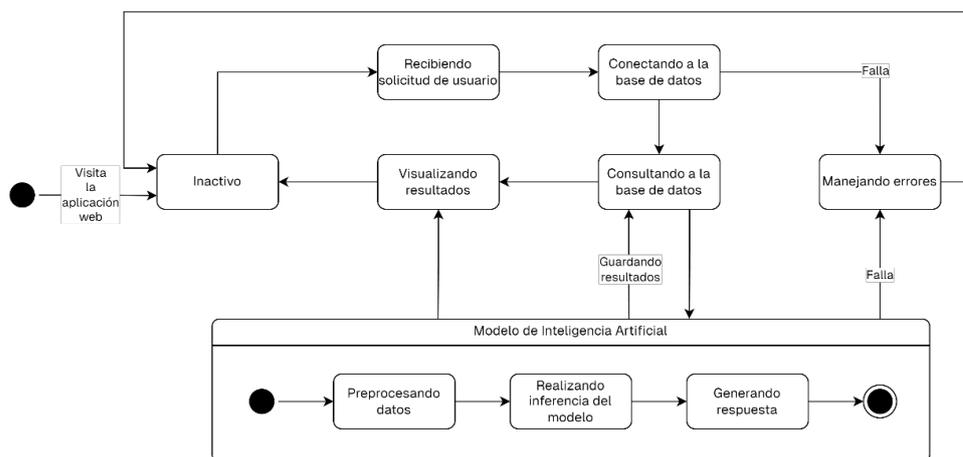
2.8.4.2 Vista Lógica.

El diagrama que se muestra en la

Figura 12, describe el flujo de la aplicación web iniciando con la visita del usuario a la aplicación web hasta que los resultados son presentados, incluyendo el manejo de errores y la integración con un modelo de inteligencia artificial para la clasificación de las IRM.

Figura 12

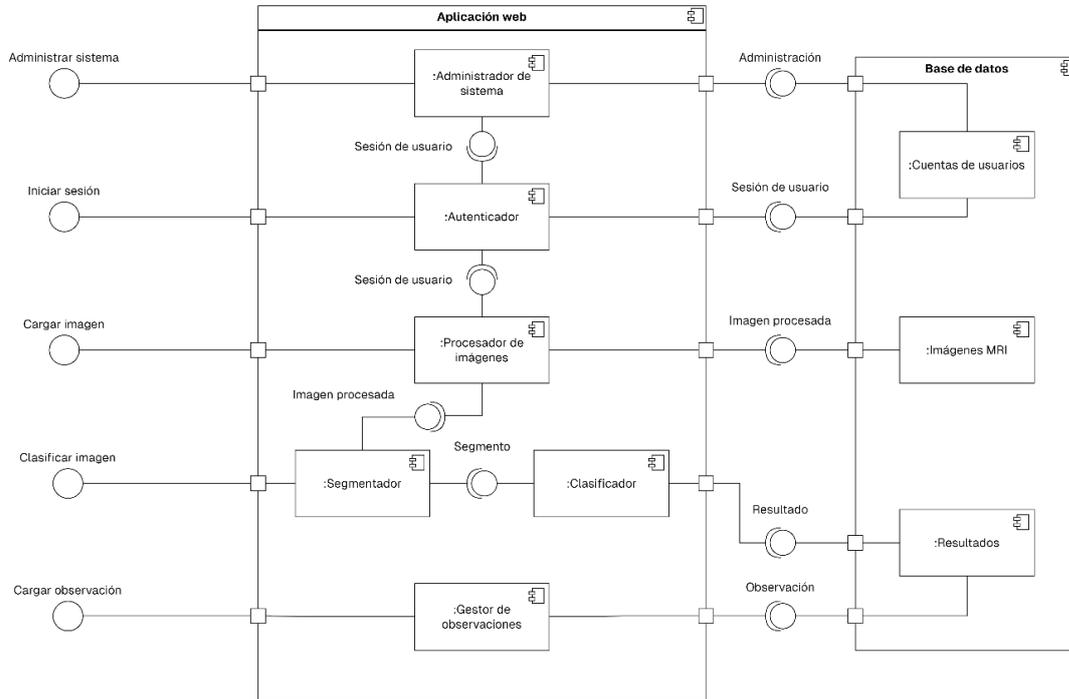
Diagrama de Estados de la aplicación web



2.8.4.3 Vista de Implementación.

La

Figura 13 ilustra la estructura modular del sistema, destacando las principales componentes y sus interacciones. La aplicación web se divide en varios módulos, siendo los más importantes los que están relacionados con el modelo de IA. El flujo comienza con la autenticación de usuarios, seguido por el procesamiento de IRM que incluye segmentación y clasificación, y finaliza con la gestión de observaciones.

Figura 13*Diagrama de Componentes de la aplicación web*

2.8.4.4 Vista de Proceso.

Esta vista no es especificada debido a que el control de concurrencia es gestionado por el servidor web y el motor de base de datos, utilizando tecnologías como DuckDB y NodeJS.

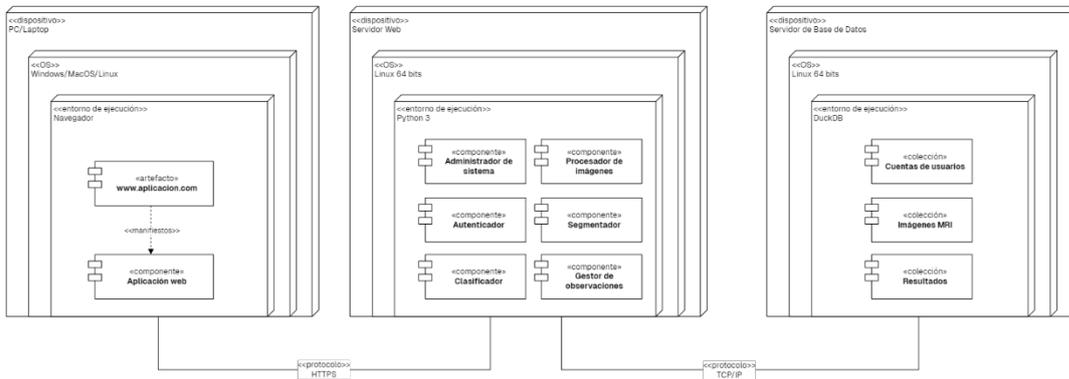
2.8.4.5 Vista de Despliegue.

La

Figura 14 muestra cómo se distribuyen los componentes del sistema a través de tres nodos principales: el dispositivo del usuario, el servidor web y el servidor de base de datos. Siendo el principal el servidor web, ya que aloja los componentes principales del sistema.

Figura 14

Diagrama de Despliegue de la aplicación web

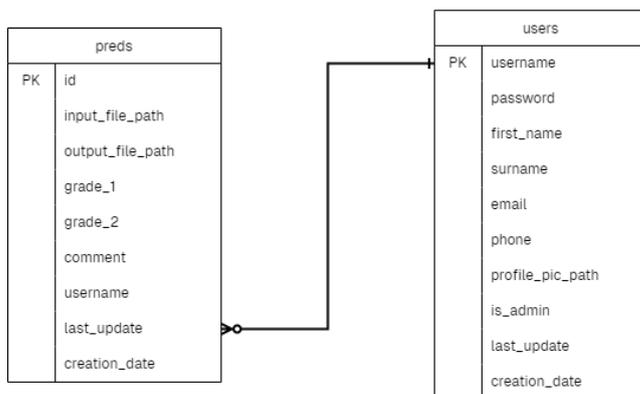


2.8.5 Diseño de bases de datos.

La Figura 15 muestra el diseño de una base de datos para la aplicación web. La entidad más importante es **users** que tiene atributos del usuario, mientras la entidad **preds** es utilizada para guardar el diagnóstico ejecutado.

Figura 15

Diagrama de Entidad Relación de la aplicación web



2.9 Plan de Implementación

En la Tabla 4 se describe el cronograma de actividades de la etapa de desarrollo, contando con tres iteraciones con sus fechas de inicio y de fin.

Tabla 4

Cronograma de actividades para el desarrollo

Iteración/Sprint	Fecha de Inicio	Fecha de Fin	Historias de Usuario/Actividades
1	08/07/2024	19/07/2024	MED-01, MED-05, MED-06, MED-08, ADMIN-01, ADMIN-02
	15/07/2024	19/07/2024	Pruebas de aceptación
2	22/07/2024	03/08/2024	MED-03, MED-04, MED-07, ADMIN-03, ADMIN-06, ADMIN-07
3	05/08/2024	16/08/2024	MED-02, ADMIN-04, ADMIN-05
	12/08/2024	16/08/2024	Pruebas de aceptación

Capítulo 3

3. Resultados y análisis

3.1 Desarrollo

El desarrollo del proyecto fue realizado a lo largo de 3 sprints, priorizando inicialmente cumplir con las historias de usuario correspondientes al rol médico, dado que las actividades de segmentación y clasificación correspondían a aquellas actividades que demandarían mayor esfuerzo.

3.1.1 *Modelo de segmentación*

Tras la revisión de distintas arquitecturas propuestas, se optó por utilizar el marco de trabajo proporcionado por “KurtLab” [51] para el entrenamiento de una versión optimizada de una 3D-Unet [52], validada para la obtención de buenos resultados usando BraTS 2023. Por otro lado, se optó por segmentar las 3 etiquetas presentadas en la base de datos con el fin de proveer más información del tumor al médico. Así, la arquitectura propuesta fue entrenada y validada en 2 sesiones de entrenamiento: Un primer entrenamiento usando las imágenes T1C y un segundo entrenamiento usando las imágenes T1C y T2F; ambos casos bajo los siguientes hiperparámetros de acuerdo con [51]:

- Funciones de pérdida: Error cuadrático promedio (MSE por sus siglas en inglés de Mean Squared Error) y Entropía Cruzada.
- Pesos de pérdida: 0.4 y 0.7 para MSE y Entropía cruzada respectivamente.
- Velocidad de aprendizaje: 0.00006
- Tasa de decaimiento: 0.995
- Épocas: 100
- Tamaño de lote: 1
- Intervalos de validación: 5

Asimismo, el desempeño de la segmentación fue evaluado usando la ecuación (2.1) para cada una de las etiquetas de segmentación de las IRM.

Para el primer entrenamiento usando las imágenes T1C, tras cumplir con las 100 épocas se obtuvo un valor DICE promedio de 0.722 (ver Figura 16). Del mismo modo, se obtuvo un valor DICE ET de 0.912 (ver Figura 18); lo cual refleja una buena capacidad del modelo para segmentar al meningioma en la IRM por medio de dicha etiqueta, situación muy similar para la etiqueta DICE SFNH presentando un valor de 0.773. Sin embargo, esto no fue el caso para la etiqueta DICE NTC puesto que su valor obtenido fue de 0.482.

Figura 16

Valores DICE promedio a lo largo de las 100 épocas (Modelo t1c)

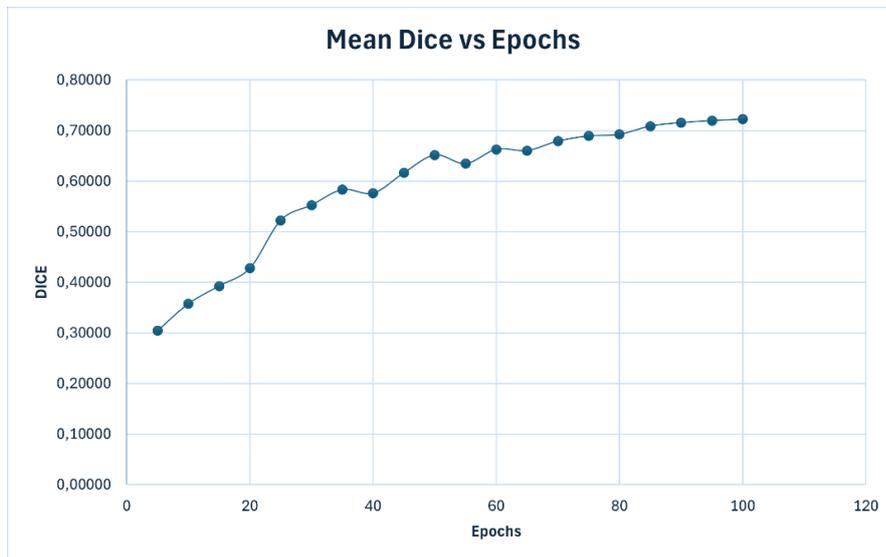
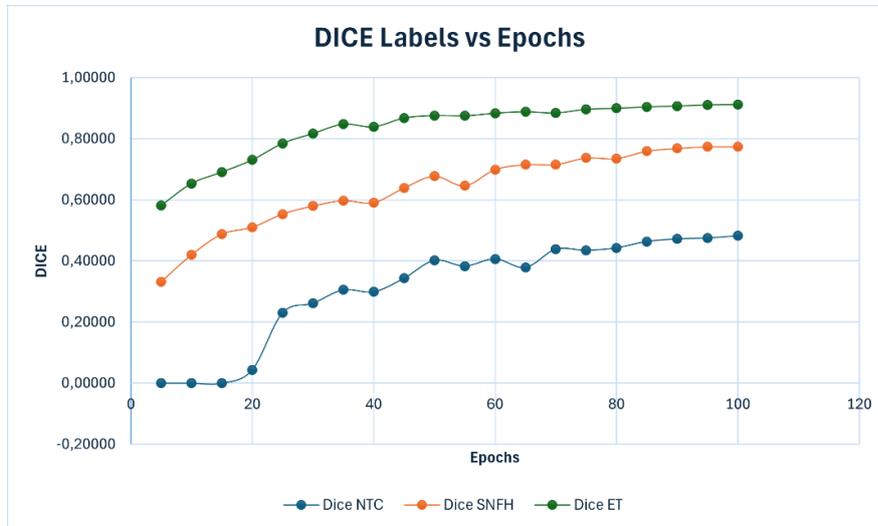


Figura 17

Valores DICE para las etiquetas de BraTS2023 a lo largo de las 100 épocas (Modelo t1c)



Respecto al entrenamiento del modelo usando imágenes T1C y T2F, los resultados obtenidos tras las 100 épocas fueron comparables con los del entrenamiento anterior obteniéndose valores DICE ET y DICE SFNH de 0.90 y 0.80 respectivamente. Sin embargo, DICE NTC presentó un valor menor en comparación a 0.43. Dado que la incorporación de la secuencia T2F no representó una mejora sustancial en los resultados para DICE, se decidió seleccionar el modelo entrenado con la secuencia T1C como modulo para la segmentación utilizado en la aplicación web.

A su vez, si bien el valor DICE promedio fue de 0.72 en promedio, el valor DICE ET fue superior en comparación (0.91), lo cual permitió que la segmentación de la etiqueta ET tuviera buenos resultados para su posterior uso en la extracción de características radiómicas. Del mismo modo, el alto valor DICE ET es comparable con otros estudios tales como en [53], donde emplearon la arquitectura DeepMedic [46] para realizar la segmentación de meningiomas usando diferentes modalidades de IRM (T1W, T2W, FLAIR y T1C) obteniendo un valor DICE de 0.91 para segmentar el tumor [53].

Por otro lado, el bajo valor obtenido para DICE NTC y DICE SFNH puede deberse al hecho de que el modelo solo fue entrenado con la secuencia T1C, impidiendo que este pueda aprender a reconocer patrones de otras secuencias como la T2F o T2C para segmentar dicha etiqueta. A su vez, las IRM usadas presentaban un desbalance, donde 339 de los 1000 sujetos presentaban la etiqueta NTC, en contraste con las otras etiquetas donde, de los 1000 sujetos, 999 presentaban la etiqueta ET y 536 la etiqueta SFNH; por lo cual, el modelo priorizó el aprendizaje de los patrones para segmentar con mayor exactitud dichas etiquetas frente a la etiqueta NTC.

3.1.2 Modelo de clasificación

Se realizó una serie de pruebas de los modelos de ML usando las características extraídas de BraTS 2023, de los 999 sujetos que poseían la etiqueta ET escalando los datos por medio del escalador estándar de scikit-learn [47]. La configuración usada en Pyradiomics para extraer las características de las imágenes se presenta en el Apéndice C. Durante el análisis de la base de datos fue prioritario descartar aquellos cuyo grado del tumor era distinto de I y II, por lo que la cantidad de observaciones se redujeron a 684. Dicha reducción en las observaciones implicó un desbalance entre las clases que debía clasificarse como meningioma; por lo cual, se utilizó técnicas de aumento de datos para mejorar el balance entre las clases. Resultando en un total de 526 observaciones.

Adicionalmente, dada la gran cantidad de características extraídas de las imágenes, fue pertinente utilizar algoritmos de selección de características para optimizar el entrenamiento y garantizar que los modelos aprendan de las características más relevantes de la IRM, por lo que, se realizó una serie de pruebas combinando distintos modelos clasificadores con diferentes algoritmos de selección y procesamiento de características para obtener un modelo con rendimiento óptimo en base a las características extraídas. La Tabla 5 lista distintos modelos y distintas técnicas de selección utilizadas.

Tabla 5

Modelos de Machine Learning y algoritmos de selección utilizados durante entrenamiento.

Modelo	Algoritmo de selección de características
Random Forest	Recursive Feature Elimination
Extra Trees	Select K Best
Gradient Boosting	Min Max Scaler
Gaussian Process Classification	Select Percentile
Ada Boost	Select From Model
Support Vector Machines RBF	Sequential Feature Selector
Logistic Regression	Selección Manual

A continuación, la Tabla 6 resume los resultados obtenidos de las distintas pruebas para los 3 mejores modelos, utilizando el valor F1 de la ecuación (2.2) como métrica. Los resultados de las otras pruebas realizadas se encuentran en mayor detalle en el Apéndice D.

Tabla 6

Resultados de mejores modelos de Machine Learning y algoritmos de selección utilizados

Modelo	Algoritmo de selección de características	Valor F1
Extra Trees	Select K Best	0.94
Random Forest	Selección del Modelo de Regresión Logística (Select From Model SFM)	0.92
Gradient Boosting	Recursive Feature Elimination	0.91

Analizando la Tabla 6, el modelo con mejores resultados fue Extra Trees empleando el algoritmo Select K Best con un valor-F1 de 0,94 siendo este el modelo seleccionado para el módulo clasificador en la interfaz de la aplicación web. Asimismo, el modelo Random Forest con el algoritmo SFM obtuvo resultados similares con un valor F1 de 0.92. Estos resultados resaltan la buena capacidad de los modelos de clasificación basados en árboles para clasificar las clases de la base de datos frente a los otros modelos de clasificación probados. Asimismo, son

comparables con los trabajos consultados en la revisión de literatura, tales como [33], donde se enlista el uso de este algoritmo en diversas pruebas para predecir el grado de malignidad del meningioma. Similar en [12], se destaca el entrenamiento de un modelo de clasificación a partir de proceso de segmentación automático para clasificar un meningioma, presentando una precisión de 0.85, siendo superiores los resultados presentados en el presente estudio. Del mismo modo, artículos como [14] y [33] destacan nuevamente la capacidad de modelos de ML para clasificar el grado del meningioma, usando la extracción de características radiómicas, e inclusive combinándolas con información radiológica para mejorar el rendimiento.

Del mismo modo, artículos como [14] y [33] destacan nuevamente la capacidad de modelos de ML para clasificar el grado del meningioma, usando la extracción de características radiómicas, e inclusive combinándolas con información radiológica para mejorar el rendimiento.

A continuación, la Tabla 7 destaca las principales características extraídas de Pyradiomics [34] que el modelo empleó para poder clasificar los resultados.

Tabla 7

Mejores características seleccionadas por el mejor modelo.

Tipo de características	Características usadas
Forma 3D	Diámetro máximo 2D de columna
Zona de Grises Primer orden	Variación de Zona Raíz cuadrada media

La Tabla 7 muestra que las características de Forma 3D fue significativa para el modelo en la ejecución de la tarea de clasificar; seguida de la Zona de grises enfocada en cuantificar las zonas en función del nivel de grises en la región [34] de interés donde se encuentra el meningioma segmentado; y, los valores estadísticos calculados de la clase Primer Orden.

Sin embargo, los resultados obtenidos se ven limitados a la extracción de características de las imágenes T1C, puesto que las otras secuencias IRM de la base de datos no poseían la etiqueta ET para extraer otras características radiómicas que pudiesen complementar el estudio.

3.1.3 Interfaz de la aplicación

Para la construcción de la interfaz de la aplicación web se tomó como base una primera iteración desarrollada en Gradio, puesto que esta plataforma fue diseñada para el alojamiento rápido y persistente de aplicaciones enfocadas en el uso de técnicas de IA. Con dichas consideraciones, se procedió a desarrollar la aplicación web de acuerdo con las historias de usuario planteadas en el Plan de Implementación.

Durante la construcción de la aplicación se presentaron problemas en la integración de los modelos de segmentación y clasificación. El primer problema surgió debido a que la configuración de las rutas usadas en Gradio no permitía cargar correctamente la imagen IRM ingresada por el usuario durante la inferencia. Asimismo, el resultado de la clasificación no era calculado correctamente por diferencias entre el formato de las características extraídas de la imagen segmentada y la base de datos usada en el entrenamiento del modelo de clasificación.

Dichos problemas fueron resueltos actualizando la configuración y forma de carga de los modelos de IA.

3.2 Resultados

3.2.1 Interfaz de la aplicación

Se priorizó realizar un diseño minimalista en contraste con la interfaz presentada en el prototipo inicial, removiendo distintos íconos de las acciones y priorizando una navegabilidad más sencilla, reduciendo la cantidad de ventanas en las que el usuario debe navegar para ver y ejecutar un diagnóstico en el caso de los médicos; y, para administrar los diferentes usuarios y diagnósticos registrados en la aplicación en el caso del administrador:

- La aplicación fue ajustada para analizar el meningioma, tal como se muestra en la, en cuanto a sus colores, distribución de botones, cambiando el color oscuro presentado en la Figura 18, añadiendo un visualizador más interactivo para que el usuario pueda navegar a lo largo de la imagen 3D IRM. (Tanto para el usuario administrador como para el usuario médico).

En la

Figura 19, Figura Figura 20, Figura

- Figura 21, Figura 22 se destaca el rediseño en la sección utilizada por el administrador para el manejo de los usuarios y las predicciones en la base de datos, en donde el administrador podrá acceder a un formulario directo para poder visualizar de mejor manera los registros, y actualizarlos o eliminarlos de manera más eficiente. Por su parte, la opción de “crear” mantiene un esquema similar para facilitar la creación de usuarios o registros de predicciones.

Cabe precisar que el formato usado de tablas para visualizar el contenido es usado para el usuario y el administrador.

Figura 18

Vista de aplicación actualizada

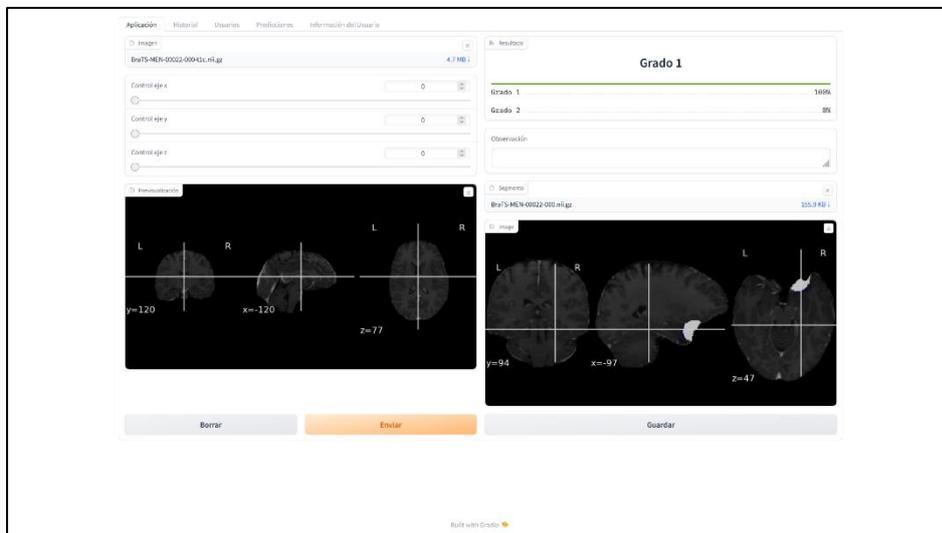


Figura 19

Vista de base de datos de usuarios actualizada

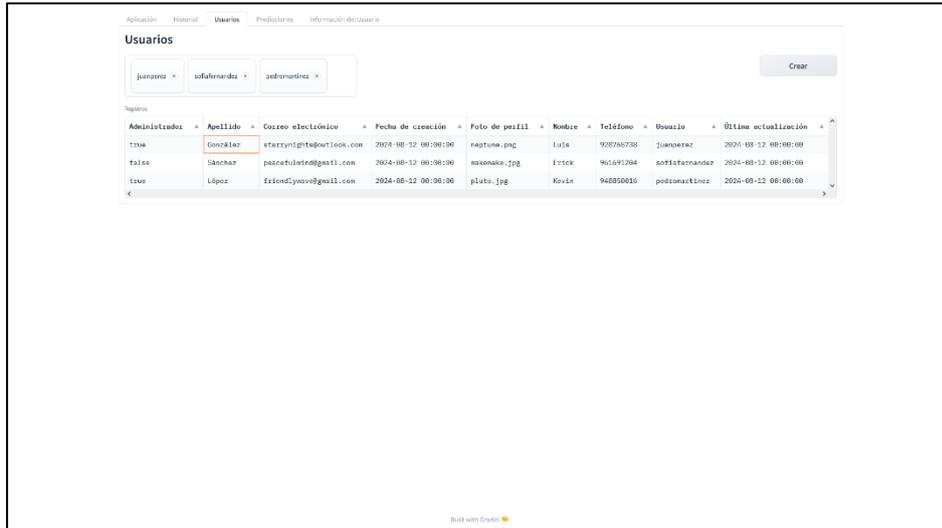


Figura 20

Vista de actualización de usuario actualizada

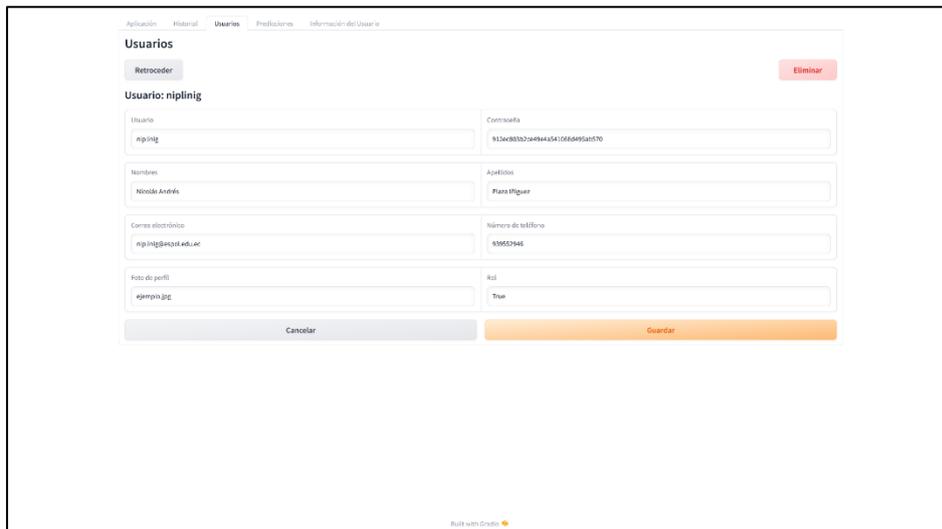


Figura 21

Vista de diagnósticos en base de datos actualizada

ID	Ruta Archivo Ingresado	Ruta Archivo Retornado	Grado 1	Grado 2	Observación	Usuario	Última actualización	Fecha de creación
30	inputs/UltraS-MEN-00004-000/UltraS-MEN-00004-000-n11.gz	outputs/UltraS-MEN-00004-000-seg-n11.gz	0.0471	0.2338	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
31	inputs/UltraS-MEN-00008-000/UltraS-MEN-00008-000-n11.gz	outputs/UltraS-MEN-00008-000-seg-n11.gz	0.9904	0.256	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
32	inputs/UltraS-MEN-00010-000-seg-n11.gz/UltraS-MEN-00010-000-seg-n11.gz	outputs/UltraS-MEN-00010-000-seg-n11.gz	0.4774	0.0725	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
33	inputs/UltraS-MEN-00010-000/UltraS-MEN-00010-000-n11.gz	outputs/UltraS-MEN-00010-000-seg-n11.gz	0.7372	0.3054	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
34	inputs/UltraS-MEN-00012-000/UltraS-MEN-00012-000-n11.gz	outputs/UltraS-MEN-00012-000-seg-n11.gz	0.0852	0.9051	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
35	inputs/UltraS-MEN-00016-000/UltraS-MEN-00016-000-n11.gz	outputs/UltraS-MEN-00016-000-seg-n11.gz	0.7385	0.4567	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00
36	inputs/UltraS-MEN-00016-000-seg-n11.gz/UltraS-MEN-00016-000-seg-n11.gz	outputs/UltraS-MEN-00016-000-seg-n11.gz	0.5525	0.7522	Observación	nfp1nfg	2024-08-19 00:00:00	2024-08-19 00:00:00

Figura 22

Vista de actualización de diagnóstico actualizada

Aplicación Historial Usuarios **Predicciones** Información del Usuario

Predicciones

Retroceder Eliminar

Predicción: 30

Identificador: 0

Grado 1: 0.0471

Grado 2: 0.2338

Observación:

Usuario: nfp1nfg

Archivo Ingresado: UltraS-MEN-00004-000-n11.gz 45 MB

Archivo Retornado: UltraS-MEN-00004-000-seg-n11.gz 77.8 KB

Cancelar Guardar

3.3 Validación del proyecto con el cliente

Después de las revisiones semanales y habiendo visto la versión actualizada de la interfaz, el cliente demostró su aceptación con lo desarrollado para con el proyecto. Asimismo, se indicaron posibles mejoras que se pueden realizar en el apartado de la interfaz como el permitir una visualización más interactiva de la IRM cargada por el usuario, y recomendaciones para el modelo de clasificación incorporado.

3.4 Análisis de costos

Para el análisis de los costos asociados al desarrollo del presente proyecto se tomó como valor de sueldo base USD 1,600 mensual para cada recurso humano empleado en el proyecto. A su vez, se consideró un valor de 50 horas/semana por cada recurso humano al usarse la metodología SCRUM. Asimismo, se consideraron 16 semanas de trabajo, tiempo que dura la MI de Computación.

Con dichas consideraciones se calculó la cantidad de horas que trabajó cada recurso usando la siguiente ecuación:

$$\text{Horas Totales por Recurso} = \text{Semanas de trabajo} * \text{Horas por Semana}$$

$$\text{Horas Totales por Recurso} = 16 [\text{semana}] * 50 \left[\frac{h}{\text{semana}} \right] = 800 [h]$$

Con la cantidad de horas totales trabajadas se calculó el costo por hora considerando el sueldo mensual previamente mencionado y la cantidad de horas trabajadas a lo largo de un mes:

$$\text{Costo por hora} = \frac{\text{Sueldo Mensual}}{\text{Horas trabajadas en 1 mes}}$$

$$\text{Costo por hora} = \frac{1,600 \left[\frac{USD}{\text{mes}} \right]}{160 \left[\frac{h}{\text{mes}} \right]}$$

$$\text{Costo por hora} = 10 \left[\frac{\text{USD}}{\text{h}} \right]$$

Con el coste total por hora se procedió a calcular el costo total del proyecto considerando los 2 recursos humanos empleados:

$$\text{Costo Total} = (\# \text{ de Recursos Humanos}) * (\text{Costo por Hora}) * (\text{Horas Trabajadas})$$

$$\text{Costo Total} = (2) * \left(10 \left[\frac{\text{USD}}{\text{h}} \right] \right) * (800 [\text{h}])$$

$$\text{Costo Total} = \text{USD}16,000.00$$

El desglose del proyecto se detalla a continuación en la Tabla 8, considerando como principales actividades: Prototipo inicial, Desarrollo Front-End, Desarrollo BackEnd, Desarrollo de Modelo de Segmentación, Desarrollo de Modelo de Clasificación y Documentación:

Tabla 8

Detalle de costos

Actividad	Horas/Actividad	Horas Trabajadas [h]	Costo/Hora [USD]	Costo Total [USD]
Prototipo inicial	120	240	10.00	2,400.00
Desarrollo Front-End	120	240	10.00	2,400.00
Desarrollo Back-End	120	240	10.00	2,400.00
Modelo de Segmentación	170	340	10.00	3,400.00
Modelo de clasificación	170	340	10.00	3,400.00
Documentación	100	200	10.00	2,000.00
Total	800	1600		16,000.00

Capítulo 4

4. Conclusiones y recomendaciones

4.1 Conclusiones

Habiéndose realizado los ajustes finales de los modelos de segmentación y clasificación, junto con el diseño de la interfaz en base a las indicaciones finales del cliente, se concluye que:

- El uso de técnicas de IA permite la carga y el análisis de imágenes de resonancia magnética T1 y FLAIR de manera automática para la segmentación y clasificación de meningiomas.
- El desarrollo del presente proyecto permitió conocer a mayor profundidad los distintos desafíos y necesidades que los doctores y el personal médico especializado enfrentan durante sus labores de análisis de imágenes IRM.
- Se desarrolló un algoritmo novedoso que permite la clasificación de lesiones cerebrales a partir de la extracción de características de la lesión en una IRM previamente segmentada.
- El uso de imágenes IRM de secuencia T1C como base para el entrenamiento del modelo de segmentación permitió la obtención de buenos resultados con un valor DICE de 0.91, frente a las imágenes T2F que no presentaron una mejora en los resultados obtenidos.
- El entrenamiento y comparación de los modelos de clasificación usando técnicas de ML, basados en características radiómicas del meningioma, obtuvo un valor F1-score de 0.94 para el clasificador Extra Trees.

4.2 Recomendaciones

Tras la culminación del trabajo realizado en el presente proyecto, se espera que la aplicación desarrollada sea empleada correctamente para apoyar en las labores de los doctores en el análisis de imágenes IRM para el diagnóstico del grado de malignidad de los meningiomas de

manera oportuna, de modo que se ahorre tiempo esencial para la planificación y ejecución adecuada del tratamiento del paciente acorde a sus necesidades. Adicional, se plantean las siguientes recomendaciones:

- El presente proyecto utilizó IRM de secuencia T1C para entrenamiento del modelo de segmentación lo que permitió obtener buenos resultados para el valor DICE, por lo que se considera pertinente analizar si el entrenar el modelo de segmentación con imágenes T2F, empleando una configuración o combinación distinta de hiperparámetros, pueda mejorar los resultados para la segmentación resultante.
- Durante el entrenamiento del modelo de clasificación se contempló el desbalance existente entre los sujetos que presentaban tumores de grado I o grado II de la base de datos usada de BraTS, lo cual afecta el rendimiento del modelo de clasificación y su capacidad de generalización; por lo cual, en trabajos posteriores, si se plantea entrenar con la misma base de datos se recomienda aumentar la cantidad de sujetos existente para cada etiqueta, por medio de técnicas de aumento de datos para mejorar su capacidad de clasificación de manera precisa.
- El entrenamiento de los algoritmos de ML y DL requirió un alto uso de tiempo y recursos computacionales que generalmente suponen un alto costo para una eficiente obtención de los resultados de la segmentación, por lo que se recomienda usar plataformas como CEDIA que permiten entrenar las arquitecturas DL, accediendo a los recursos computacionales de manera gratuita.

Las recomendaciones planteadas se enfocan en diferentes aspectos que se presentaron como desafíos durante el desarrollo del presente proyecto, y tienen como meta brindar una guía o consejos esenciales que permitieran facilitar la reproducción de los resultados obtenidos.

Adicionalmente, al emplear modelos de ML y DL, se usan arquitecturas que se encuentran en constante mejora, por lo que existe la posibilidad de que a futuro arquitecturas más sofisticadas puedan obtener mejores resultados que los obtenidos actualmente. A su vez, el presente proyecto sirve como guía para futuros estudios que busquen clasificar el grado de malignidad de meningiomas al emplear un enfoque novedoso como lo fue la clasificación de características radiómicas de un tumor previamente segmentado.

Referencias

- [1] Q. T. Ostrom, M. Price, C. Neff, G. Cioffi, K. A. Waite, C. Kruchko y J. S. Barnholtz-Sloan, «CBTRUS Statistical Report: Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2016—2020,» *Neuro-Oncology*, vol. 25, n° Supplement_4, pp. iv1-iv99, 2023.
- [2] D. N. Louis, A. Perry, P. Wesseling, D. J. Brat, I. A. Cree, D. Figarella-Branger, C. Hawkins, H. K. Ng, S. M. Pfister, G. Reifenberger, R. Soffietti, A. von Deimling y D. W. Ellison, «The 2021 WHO Classification of Tumors of the Central Nervous System: a summary.,» *Neuro Oncol*, vol. 23, n° 8, pp. 1231-1251, 2021.
- [3] M. Nowosielski, N. Galldiks, S. Iglseder, P. Kickingereder, A. von Deimling, M. Bendszus, W. Wick y F. Sahm, «Diagnostic challenges in meningioma.,» *Neuro-oncology*, vol. 19, n° 12, p. 1588–1598, 2017.
- [4] M. Javaid, A. Haleem, R. Pratap Singh y M. Ahmed, «Computer vision to enhance healthcare domain: An overview of features, implementation, and opportunities,» *Intelligent Pharmacy*, 2024.
- [5] M. Kaur, P. Mann, R. Rani, G. Jaiswal, A. Sharma y R. Kumar, «MRI Image Segmentation using Deep Learning for Brain Tumor Detection,» de *2023 10th International Conference on Computing for Sustainable Global Development (INDIACom)*, 2023.
- [6] M. R. Ramadhani, I. Soesanti y I. Hidayah, «Brain Tumor Classification Based on Deep Learning Algorithms: A Systematic Literature Review,» de *2023 8th International Conference on Information Technology and Digital Applications (ICITDA)*, 2023.

- [7] A. H. Zamanipoor Najafabadi, M. C. M. Peeters, L. Dirven, D. J. Lobatto, J. L. Groen, M. L. Broekman, S. M. Peerdeman, W. C. Peul, M. J. B. Taphoorn y W. R. van Furth, «Impaired health-related quality of life in meningioma patients—a systematic review,» *Neuro-Oncology*, vol. 19, n° 7, pp. 897-907, 2016.
- [8] H. Zhu, Q. Fang, H. He, J. Hu y K. Xu, «Automatic Prediction of Meningioma Grade Image Based on Data Amplification and Improved Convolutional Neural Network.,» *Computational and mathematical methods in medicine*, vol. 2019, p. 7289273, 2019.
- [9] T. Banzato, F. Causin, A. Della Puppa, G. Cester, L. Mazzai y A. Zotti, «Accuracy of deep learning to differentiate the histopathological grading of meningiomas on MR images: A preliminary study.,» *Journal of magnetic resonance imaging : JMRI*, vol. 50, n° 4, pp. 1152-1159, 2019.
- [10] M. Alkhodari, O. Hassanin y S. Dhou, «A Comparative Study of Meningioma Tumors Segmentation Methods from MR Images,» de *2020 3rd International Conference on Signal Processing and Information Security (ICSPIS)*, Dubai, 2020.
- [11] A. K. Sahoo y P. Parida, «A Clustering Based Approach For Meningioma Tumors Extraction From Brain MRI Images,» de *2020 IEEE International Symposium on Sustainable Energy, Signal Processing and Cyber Security (iSSSC)*, Gunupur, 2020.
- [12] L. Yang, T. Wang, J. Zhang, S. Kang, S. Xu y K. Wang, «Deep learning–based automatic segmentation of meningioma from T1-weighted contrast-enhanced MRI for preoperative meningioma differentiation using radiomic features,» *BMC Medical Imaging*, vol. 24, n° 1, p. 56, 2024.

- [13] A. Boaro, J. R. Kaczmarzyk, V. K. Kavouridis, M. Harary, M. Mammi, H. Dawood, A. Shea, E. Y. Cho, P. Juvekar, T. Noh, A. Rana, S. Ghosh y O. Arnaout, «Deep neural networks allow expert-level brain meningioma segmentation and present potential for improvement of clinical practice,» *Scientific Reports*, vol. 12, n° 1, p. 15462, 14 Septiembre 2022.
- [14] M. Li, L. Liu, J. Qi, Y. Qiao, H. Zeng, W. Jiang, R. Zhu, F. Chen, H. Huang y S. Wu, «MRI-based machine learning models predict the malignant biological behavior of meningioma,» *BMC Medical Imaging*, vol. 23, n° 1, p. 141, 2023.
- [15] J. R. Schubart, M. B. Kinzie y E. Farace, «Caring for the brain tumor patient: Family caregiver burden and unmet needs,» *Neuro-Oncology*, vol. 10, n° 1, pp. 61-72, 2008.
- [16] N. Xiao, D. Zhu y S. Xiao, «Effects of continued psychological care toward brain tumor patients and their family members' negative emotions,» *Journal of Cancer Research and Therapeutics*, vol. 14, n° 1, pp. S202-S207, 2018.
- [17] R. A. Buerki, C. M. Horbinski, T. Kruser, P. M. Horowitz, C. D. James y R. V. Lukas, «An overview of meningiomas,» *Future oncology (London, England)*, vol. 14, n° 21, p. 2161–2177, 2018.
- [18] C. Ogasawara, B. D. Philbrick y D. C. Adamson, «Meningioma: A Review of Epidemiology, Pathology, Diagnosis, Treatment, and Future Directions,» *Biomedicines*, vol. 9, n° 3, 2021.
- [19] J. Wiemels, M. Wrensch y E. B. Claus, «Epidemiology and etiology of meningioma,» *Journal of Neuro-Oncology*, vol. 99, n° 3, p. 307–314, 2010.

- [20] K. Kerr, K. Qualmann, Y. Esquenazi, J. Hagan y D. H. Kim, «Familial Syndromes Involving Meningiomas Provide Mechanistic Insight Into Sporadic Disease.» *Neurosurgery*, vol. 83, n° 6, p. 1107–1118, 2018.
- [21] I. Maggio, E. Franceschi, A. Tosoni, V. D. Nunno, L. Gatto, R. Lodi y A. A. Brandes, «Meningioma: not always a benign tumor. A review of advances in the treatment of meningioma.» *CNS oncology*, vol. 10, n° 2, 2021.
- [22] F. Nassiri, S. Suppiah, J. Z. Wang, J. H. Badhiwala, K. Juraschka, Y. Meng, R. Nejad, K. Au, N. E. Willmarth, M. Cusimano y G. Zadeh, «How to live with a meningioma: experiences, symptoms, and challenges reported by patients.» *Neuro-oncology advances*, vol. 2, n° 1, 2020.
- [23] R. Goldbrunner, P. Stavrinou, M. D. Jenkinson, F. Sahm, C. Mawrin, D. C. Weber, M. Preusser, G. Minniti, M. Lund-Johansen, F. Lefranc, E. Houdart, K. Sallabanda, E. Le Rhun, D. Nieuwenhuizen, G. Tabatabai, R. Soffietti y M. Weller, «EANO guideline on the diagnosis and management of meningiomas.» *Neuro-Oncology*, vol. 23, n° 11, pp. 1821-1834, 2021.
- [24] A. Sohail, N. A. Nawaz, A. A. Shah, S. Rasheed, S. Ilyas y M. K. Ehsan, «A Systematic Literature Review on Machine Learning and Deep Learning Methods for Semantic Segmentation.» *IEEE Access*, vol. 10, pp. 134557-134570, 2022.
- [25] C. Sutton y A. McCallum, «An Introduction to Conditional Random Fields for Relational Learning.» de *Introduction to Statistical Relational Learning*, The MIT Press, 2007.
- [26] C. Davatzikos, S. Rathore, S. Bakas, S. Pati, M. Bergman, R. Kalarot, P. Sridharan, A. Gastounioti, N. Jahani, E. Cohen, H. Akbari, B. Tunc, J. Doshi, D. Parker y M. Hsieh, «Cancer imaging phenomics toolkit: quantitative imaging analytics for

- precision diagnostics and predictive modeling of clinical outcome,» *Journal of Medical Imaging*, vol. 5, n° 01, p. 380–394, 2018.
- [27] S. Pati, A. Singh, S. Rathore, A. Gastounioti, M. Bergman, P. Ngo, S. M. Ha, D. Bounias, J. Minock, G. Murphy, H. Li, A. Bhattarai, A. Wolf, P. Sridaran, R. Kalarot, H. Akbari, A. Sotiras, S. P. Thakur, R. Verma, R. T. Shinohara, P. Yushkevich, Y. Fan, D. Kontos, C. Davatzikos y S. Bakas, «The cancer imaging phenomics toolkit (CaPTk): Technical overview,» *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11993 LNCS, pp. 380-394, 2020.
- [28] D. Bouget, D. Alsinan, D. Alsinan, R. H. Helland, A. Pedersen, O. Solheim y I. Reinertsen, «Raidionics: an open software for pre- and postoperative central nervous system tumor segmentation and standardized reporting,» *Scientific Reports*, vol. 13, n° 1, p. 15570, 2023.
- [29] M. Masoud, P. Reddy, F. Hu y S. Plis, «Brainchop: Next Generation Web-Based Neuroimaging Application,» 2023.
- [30] W. Ponikiewski y J. Nalepa, «Deep Learning Meets Radiomics For End-To-End Brain Tumor MRI Analysis,» de *2022 IEEE International Conference on Image Processing (ICIP)*, Bordeaux, 2022.
- [31] J. Hu, Y. Zhao, M. Li, J. Liu, F. Wang, Q. Weng, X. Wang y D. Cao, «Machine learning-based radiomics analysis in predicting the meningioma grade using multiparametric MRI,» *European Journal of Radiology*, vol. 131, p. 109251, 2020.
- [32] L. Ugga, T. Perillo, R. Cuocolo, A. Stanzione, V. Romeo, R. Green, V. Cantoni y A. Brunetti, «Meningioma MRI radiomics and machine learning: systematic review,

- quality score assessment, and meta-analysis,» *Neuroradiology*, vol. 63, n° 8, pp. 1293-1304, 2021.
- [33] E. Neromyliotis, T. Kalamatianos, A. Paschalis, S. Komaitis, K. N. Fountas, E. Z. Kapsalaki, G. Stranjalis y I. Tsougos, «Machine Learning in Meningioma MRI: Past to Present. A Narrative Review,» *Journal of Magnetic Resonance Imaging*, vol. 55, n° 1, pp. 48-60, 2022.
- [34] J. J. Van Griethuysen, A. Fedorov, C. Parmar, A. Hosny, N. Aucoin, V. Narayan, R. G. Beets-Tan, J.-C. Fillion-Robin, S. Pieper y H. J. Aerts, «Computational radiomics system to decode the radiographic phenotype,» *Cancer research*, vol. 77, n° 21, pp. 104-107, 2017.
- [35] B. Panduri y O. S. Rao, «A Survey on Brain Tumour Segmentation Techniques in Deep Learning,» *International Journal of Intelligent Systems and Applications in Engineering*, vol. 12, n° 7s, pp. 412-425, December 2024.
- [36] S. Roozpeykar, M. Azizian, Z. Zamani, M. R. Farzan, H. A. Veshnavei, N. Tavoosi, A. Toghyani, A. Sadeghian y M. Afzali, «Contrast-enhanced weighted-T1 and FLAIR sequences in MRI of meningeal lesions.,» *American journal of nuclear medicine and molecular imaging*, vol. 12, n° 2, 2022.
- [37] P. Gupta, S. Srivastava, R. Gupta y S. Kumar, «Brain Cancer Detection With MRI and ML,» de *2024 2nd International Conference on Disruptive Technologies (ICDT)*, Greater Noida, 2024.
- [38] Y. Xie, F. Zaccagna, L. Rundo, C. Testa, R. Agati, R. Lodi, D. N. Manners y C. Tonon, «Convolutional Neural Network Techniques for Brain Tumor Classification (from 2015 to 2022): Review, Challenges, and Future Perspectives,» *Diagnostics*, vol. 12, n° 8, 2022.

- [39] C. Chen, Y. Cheng, J. Xu, T. Zhang, X. Shu, W. Huang, Y. Hua, Y. Zhang, Y. Teng, L. Zhang y J. Xu, «Automatic meningioma segmentation and grading prediction: A hybrid deep-learning method,» *Journal of Personalized Medicine*, vol. 11, nº 8, 2021.
- [40] D. Bouget, A. Pedersen, S. A. M. Hosainey, O. Solheim y I. Reinertsen, «Meningioma Segmentation in T1-Weighted MRI Leveraging Global Context and Attention Mechanisms,» *Frontiers in Radiology*, vol. 1, September 2021.
- [41] D. LaBella, M. Adewole, M. Alonso-Basanta y e. al., «The ASNR-MICCAI Brain Tumor Segmentation (BraTS) Challenge 2023: Intracranial Meningioma,» 12 Mayo 2023. [En línea]. Available: <http://arxiv.org/abs/2305.07642>. [Último acceso: 24 Junio 2024].
- [42] K. Kamnitsas, C. Ledig, V. F. Newcombe, J. P. Simpson, A. D. Kane, D. K. Menon, D. Rueckert y B. Glocker, «Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation,» *Medical Image Analysis*, vol. 36, pp. 61-78, February 2017.
- [43] H. Yang, W. Huang, K. Qi, C. Li, X. Liu, M. Wang, H. Zheng y S. Wang, «CLCI-Net: Cross-Level Fusion and Context Inference Networks for Lesion Segmentation of Chronic Stroke,» *Medical Image Computing and Computer Assisted Intervention -- MICCAI 2019*, vol. 11766, p. 266–274, 2019.
- [44] N. Giakoumoglou, «PyFeats: Open-source software for image feature extraction,» *GitHub repository*, 2021.
- [45] M. Futrega, A. Milesi, M. Marcinkiewicz y P. Ribalta, «Optimized U-Net for Brain Tumor Segmentation,» *International MICCAI brainlesion workshop*, 2021.

- [46] K. Kamnitsas, C. Ledig, V. F. Newcombe, J. P. Simpson, A. D. Kane, D. K. Menon, D. Rueckert y B. Glocker, «Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation,» *Medical Image Analysis*, vol. 36, pp. 61-78, 2017.
- [47] scikit-learn developers, «Scikit-Learn,» 2024. [En línea]. Available: <https://scikit-learn.org/stable/about.html>.
- [48] L. R. Dice, «Measures of the Amount of Ecologic Association Between Species,» *Ecology*, vol. 26, n° 3, pp. 297--302, 1945.
- [49] M. Hossin y M. N. Sulaiman, «A review on evaluation metrics for data classification evaluations,» *International journal of data mining & knowledge management process*, vol. 5, n° 2, pp. 01-11, 2015.
- [50] P. B. Kruchten, «The 4+1 View Model of architecture,» *IEEE Software*, vol. 12, n° 6, pp. 42-50, 1995.
- [51] T. Ren, E. Honey, H. Rejala, A. Sharma, A. Chopra y M. Kurt, «An optimization framework for processing and transfer learning for the brain tumor segmentation,» *ArXiv preprint ArXiv:2402.07008*, 2024.
- [52] M. Futrega, A. Milesi, M. Marcinkiewicz y P. Ribalta, «Optimized U-Net for Brain Tumor Segmentation,» de *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, Cham, 2022.
- [53] K. R. Laukamp, L. Pennig, F. Thiele, R. Reimer, L. Görtz, G. Shakirin, D. Zopfs, M. Timmer, M. Perkuhn y J. Borggrefe, «Automated Meningioma Segmentation in Multiparametric MRI,» *Clinical Neuroradiology*, vol. 31, n° 2, pp. 357-366, 2021.

Apéndice A

Historias de Usuario para el usuario Médico

Identificador (ID) de la Historia	Enunciado de la Historia				Criterios de Aceptación			
	Rol	Característica / Funcionalidad	Razón / Resultado	Número (#) de Escenario	Criterio de Aceptación (Título)	Contexto	Evento	Resultado / Comportamiento esperado
MED-01	Como un Médico	Necesito cargar una imagen IRM	Con la finalidad de poder visualizarla en pantalla	1	Carga Exitosa	En caso de que se seleccione una imagen IRM en formato NIFTI	Cuando se presiona el botón "Cargar Imagen"	El Sistema muestra por pantalla una previsualización de la imagen IRM cargada
				2	Carga Fallida	En caso de que se seleccione una imagen IRM con un formato no adecuado	Cuando se presiona el botón "Cargar Imagen"	El Sistema mostrará un mensaje por pantalla indicando que la imagen no pudo ser cargada indicándole al usuario que cargue una imagen nuevamente.
MED-02	Como un Médico	Necesito borrar la imagen IRM cargada	Con la finalidad de poder cargar otra imagen IRM	1	Imagen incorrecta	En caso de que la imagen cargada no sea la imagen que se quiere procesar	Cuando se oprima el botón "Borrar Imagen"	El Sistema dejará de mostrar la imagen previamente cargada, se abilitará el botón de carga de imagen
MED-03	Como un Médico	Necesito visualizar el progreso de procesamiento de imagen	Con la finalidad de saber que mi imagen IRM sea está procesando correctamente	1	Procesando	En caso de que la imagen esté correctamente cargada	Cuando oprime el botón "Ejecutar diagnóstico"	El sistema mostrará una barra de carga que representa el progreso de la imagen durante la segmentación y clasificación del meningioma
MED-04	Como un Médico	Necesito visualizar el resultado de la segmentación del meningioma	Con la finalidad de conocer en que parte de la IRM se encuentra el meningiomas	1	Meningioma segmentado	En caso de que la imagen procesada presenta un meningioma y fue segmentado correctamente	Cuando se termina de procesar la imagen correctamente	El Sistema presenta la imagen IRM procesada con el meningioma delimitado en pantalla
				2	Meningioma no segmentado	En caso de que la imagen procesada presenta el meningioma pero no lo segmenta correctamente	Cuando se termina de procesar la imagen correctamente	El sistema presenta la imagen procesada sin modificaciones
MED-05	Como un Médico	Necesito visualizar el grado de malignidad del meningioma	Con la finalidad de obtener información que me ayude a obtener un diagnóstico preciso	1	Meningioma clasificado	En caso de que se obtuvo un resultado de la segmentación	cuando se termina de procesar la imagen correctamente	el sistema presenta el resultado de la clasificación con el porcentaje de pertenencia a la clase
				2	Meningioma no clasificado	En caso de que no se obtuvo un resultado de la segmentación	cuando se termina de procesar la imagen correctamente	el sistema presenta el resultado de la clasificación con el porcentaje de pertenencia a la clase
MED-06	Como un Médico	Necesito escribir un comentario sobre el diagnóstico ejecutado	Con la finalidad de brindar retroalimentación sobre el resultado generado	1	Comentario con contenido	En caso de que el médico escriba un sus comentarios u observaciones sobre el resultado del diagnóstico en la casilla de texto	cuando el médico da clic al botón "Enviar"	el sistema mostrará un mensaje indicando que el comentario/observación sobre el diagnóstico fue enviado correctamente.
				2	Comentario sin contenido	En caso de que el médico no haya escrito ningún comentario u observación sobre el resultado del diagnóstico en la casilla de texto	cuando el médico da clic al botón "Enviar"	el sistema mostrará un mensaje de error indicando que no se permite el envío de comentarios en blanco.
MED-07	Como un Médico	Necesito guardar en mi dispositivo el resultado del diagnóstico	Con la finalidad de preservar los resultados obtenidos y revisarlos cuando lo desee	1	Guardado exitoso	En caso de que el médico desee guardar el resultado obtenido obtenido por la aplicación y este se logre guardar correctamente	cuando el médico de clic en el botón "Guardar diagnóstico"	el sistema iniciará la descarga del resultado del diagnóstico guardándolo en el dispositivo como un archivo de texto estructurado
MED-08	Como un Médico	Necesito visualizar los diagnósticos que he ejecutado	Con la finalidad de revisarlos en la Aplicación web cuando lo considere oportuno	1	Existen diagnósticos	En caso de que el médico haya realizado al menos 1 diagnóstico	cuando el médico da clic al botón "Ver Diagnósticos"	el sistema mostrará una tabla con el detalle de los diagnósticos que ha ejecutado.
				2	No existen diagnósticos	En caso de que el médico no haya realizado diagnósticos previamente	cuando el médico da clic al botón "Ver Diagnósticos"	el sistema mostrará un mensaje indicándole que no hay diagnósticos disponibles para mostrar.

Historias de Usuario para el usuario Administrador

Identificador (ID) de la Historia	Enunciado de la Historia				Criterios de Aceptación			
	Rol	Característica / Funcionalidad	Razón / Resultado	Número (#) de Escenario	Criterio de Aceptación (Título)	Contexto	Evento	Resultado / Comportamiento esperado
ADMIN-01	Como un Administrador	Necesito iniciar sesión en la aplicación web	Con la finalidad de acceder al portal de administrador que me permita realizar las actividades de administración en la aplicación web.	1	Login admin exitoso	En caso de que el administrador desee iniciar sesión con su usuario y contraseña autorizado/correcto	cuando el administrador ingrese su usuario y contraseña y de clic en el botón "Iniciar sesión"	el sistema autentificará sus datos y lo redirigirá a la pantalla del panel de administración de la aplicación web.
				2	Login admin fallido	En caso de que el administrador desee iniciar sesión con su usuario y contraseña no autorizado/incorrecto	cuando el médico de clic en el botón "Guardar" diagnóstico	el sistema mostrará un mensaje indicando que el usuario y/o contraseña son incorrectos indicándole al usuario que ingrese nuevamente su información
ADMIN-02	Como un Administrador	Necesito crear/regar a los nuevos usuarios (médicos/administradores) en la aplicación web	Con la finalidad de brindar acceso a los a las diferentes herramientas de la aplicación web en función de su rol (médico o administrador)	1	Registro usuario médico exitoso	En caso de que el administrador haya dado clic al botón "Registrar médico" y haya llenado la información del nuevo médico correctamente en el formulario de usuario médico en la página web,	cuando el administrador de clic en el botón "Crear usuario médico"	el sistema mostrará una notificación indicando que el nuevo usuario médico fue creado de manera correcta.
				2	Registro usuario administrador exitoso	En caso de que el administrador haya dado clic al botón "Registrar administrador" y haya llenado correctamente la información del nuevo administrados en el formulario de usuario administrador en la página web,	cuando el administrador de clic en el botón "Crear usuario administrador"	el sistema mostrará una notificación indicando que el nuevo usuario administrador fue creado de manera correcta con los permisos adecuados.
				3	Registro usuario médico cancelado	En caso de que el administrador haya dado clic al botón "Registrar médico" y haya llenado la información del nuevo médico de forma incorrecta en el formulario de usuario médico en la página web,	cuando el administrador de clic en el botón "Volver"	el sistema redirigirá a usuario administrador en hacia el página principal del panel de administración.
				4	Registro usuario administrador cancelado	En caso de que el administrador haya dado clic al botón "Registrar administrador" y haya llenado incorrectamente la información del nuevo administrador en el formulario de usuario administrador en la página web	cuando el administrador de clic en el botón "Volver"	el sistema redirigirá a usuario administrador en hacia el página principal del panel de administración.
ADMIN-03	Como un Administrador	Necesito visualizar los usuarios registrados (médicos/administradores) en la aplicación web	Con la finalidad de conocer los distintos médicos registrados que utilizan la aplicación web y a los usuarios con permisos de administrador	1	Visualización con usuarios	En caso de que haya al menos 1 usuario (médico o administrador) registrado en la aplicación web	cuando el administrador de clic en el botón "Ver Usuarios"	el sistema mostrará en formato de tabla a los diferentes usuarios (médicos/administradores) registrados en la aplicación web junto con información relacionada.
				2	Visualización sin usuarios	En caso de que no se hayan usuarios registrados en la aplicación web	cuando el administrador de clic en el botón "Ver Usuarios"	el sistema mostrará un mensaje indicando que no hay registros de usuarios disponibles para mostrar
ADMIN-04	Como un Administrador	Necesito actualizar la información asociada a los usuarios registrados (médicos/administradores) en la aplicación web	Con la finalidad de que cada usuario registrado posea su información y permisos actualizados	1	Actualización exitosa	En caso de que el administrador haya dado clic en "Actualizar información de usuario" y haya llenado la nueva información del usuario médico o administrador	cuando el administrador de clic en el botón "Guardar cambios"	el sistema mostrará un mensaje indicando que el usuario fue actualizado correctamente y se mostrará nuevamente la página de los usuarios a manera de tabla.
				2	Actualización cancelada	En caso de que el administrador haya dado clic en "Actualizar información de usuario" y haya llenado la nueva información incorrecta del usuario médico o administrador	cuando el administrador de clic en el botón "Cancelar cambios"	el sistema cerrará la ventana de actualización y mostrará nuevamente la página de los usuarios a manera de tabla.
ADMIN-05	Como un Administrador	Necesito eliminar a los usuarios registrados (médicos/administradores) en la aplicación web	Con la finalidad de que eliminar el acceso a usuarios que ya no estén autorizados en utilizar la aplicación web	1	Eliminación exitosa	En caso de que el administrador haya dado clic en el botón "Eliminar usuario"	cuando el administrador de clic en el botón "Confirmar"	el sistema mostrará un mensaje indicando que el usuario fue borrado de los registros correctamente y se mostrará nuevamente la página de los usuarios a manera de tabla.
				2	Eliminación cancelada	En caso de que el administrador haya dado clic en el botón "Eliminar usuario"	cuando el administrador de clic en el botón "Cancelar"	el sistema cerrará la ventana de eliminación y mostrará nuevamente la página de los usuarios a manera de tabla.
ADMIN-06	Como un Administrador	Necesito visualizar los diagnósticos ejecutados por los médicos	Con la finalidad de conocer los resultados obtenidos y posibles comentarios realizados por los médicos	1	Visualización con diagnósticos	En caso de que haya al menos 1 diagnóstico que se haya registrado en la aplicación web	cuando el administrador de clic en el botón "Ver diagnósticos"	el sistema mostrará en formato de tabla a los diferentes diagnósticos registrados en la aplicación web junto con información relacionada.
				2	Visualización fallida	En caso de que no haya ningún diagnóstico registrado en la aplicación web	cuando el administrador de clic en el botón "Ver diagnósticos"	el sistema mostrará un mensaje indicando que no hay registros de diagnósticos disponibles para mostrar
ADMIN-07	Como un Administrador	Necesito guardar los resultados de los diagnósticos realizados por los médicos	Con la finalidad de preservar los resultados obtenidos y revisarlos cuando se considere conveniente	1	Guardado exitoso	En caso de que el administrador haya seleccionado un diagnóstico de un médico para ver su información	cuando el médico de clic en el botón "Guardar diagnóstico"	el sistema iniciará la descarga del resultado del diagnóstico guardándolo en el dispositivo como un archivo de texto estructurado

Apéndice B

Se detallan a continuación los requerimientos del Administrador adicionales a los detallados previamente en el Flujo de ventanas:

Actualizar la información básica del perfil (ver Figura 23, Figura

- Figura 24).

Crear un usuario en la aplicación web (ver Figura 25, Figura

Figura 26, Figura Figura 27, Figura

- Figura 28).

Actualizar un usuario registrado en la aplicación web (ver Figura 29, Figura

Figura 30, Figura Figura 31, Figura

- Figura 32).

Eliminar un usuario registrado en la aplicación web (ver Figura 33, Figura

- Figura 34, Figura Figura 35).

Figura 23

Vista de actualización de información de perfil de administrador (I)



The screenshot shows a web interface for updating user information. At the top left is the 'espol' logo, and at the top right is the username 'johndoe27'. Below the logo is a hamburger menu icon, and below the username is a right-pointing arrow icon. The main heading is 'Actualización de información de usuario'. To the left of the form is a circular profile picture placeholder. The form contains the following fields:

Nombres	<input type="text" value="John"/>	Apellidos	<input type="text" value="Doe"/>
Nombre de usuario	<input type="text" value="johndoe27"/>		
Correo Electrónico	<input type="text" value="johndoe_test@mail.com"/>		
Teléfono	<input type="text" value="0987654321"/>		

At the bottom of the form are two buttons: a dark blue 'Volver' button and a green 'Actualizar información' button.

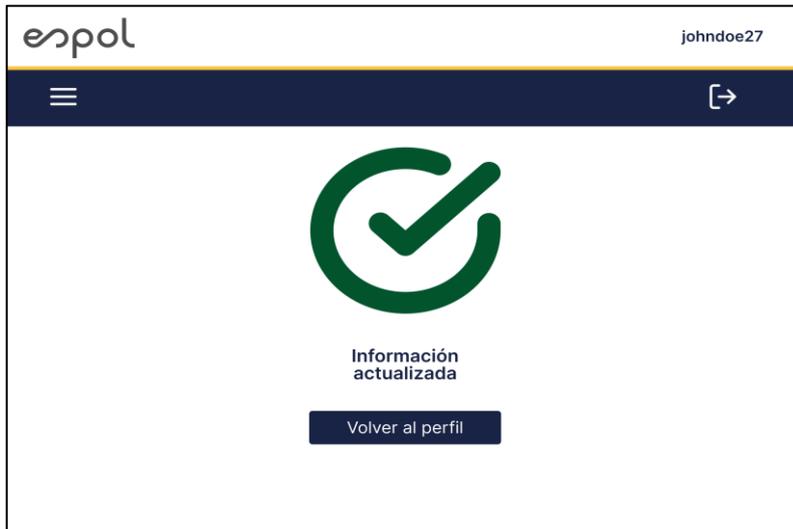
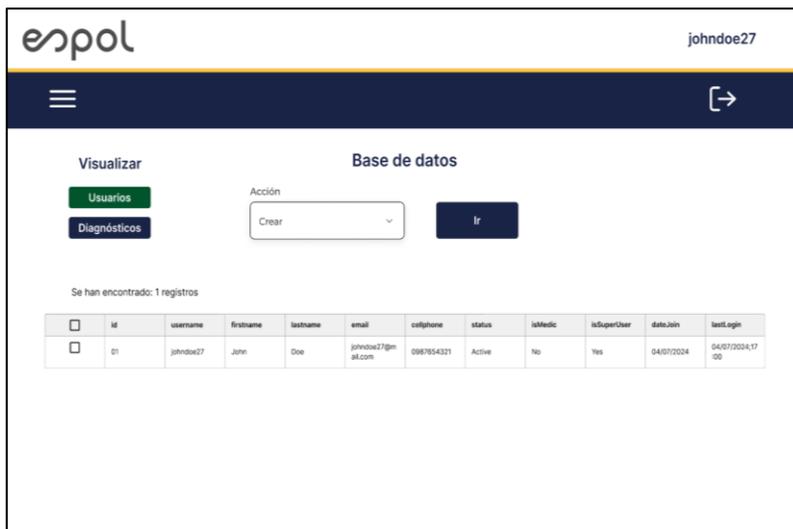
Figura 24*Vista de actualización de información de perfil de administrador (II)***Figura 25***Vista de creación de usuario (I)*

Figura 26*Vista de creación de usuario (II)*

The screenshot shows the 'Crear usuario' form in the espol system. The header includes the 'espol' logo and the user 'johndoe27'. A navigation bar contains a menu icon and a back arrow. The form includes a 'Volver' button and the title 'Crear usuario'. The fields are: 'Nombre' (Jane), 'Apellidos' (Parker), 'Nombre de usuario' (janep56), 'Correo Electrónico' (janep56@mail.com), and 'Teléfono' (0987776321). The 'Rol' section has radio buttons for 'Medico' (selected) and 'Administrador'. A green 'Crear usuario' button is at the bottom.

Figura 27*Vista de creación de usuario (III)*

This screenshot shows the same 'Crear usuario' form as in Figure 26, but with a confirmation dialog box overlaid. The dialog is titled 'Confirmación' and asks: '¿Desea crear el usuario médico "janep56" para Jane Parker?'. It features a red 'Cancelar' button and a dark blue 'Crear usuario' button. The background form is dimmed.

Figura 28

Vista de creación de usuario (IV)

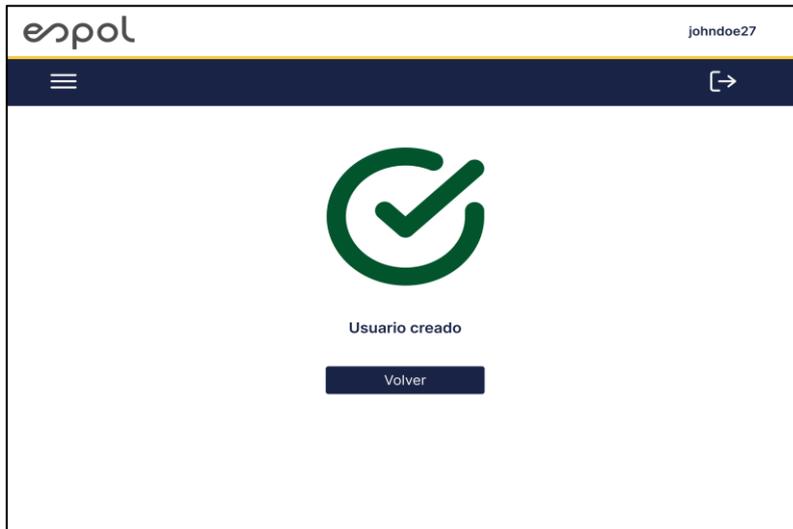


Figura 29

Vista de actualización de usuario (I)

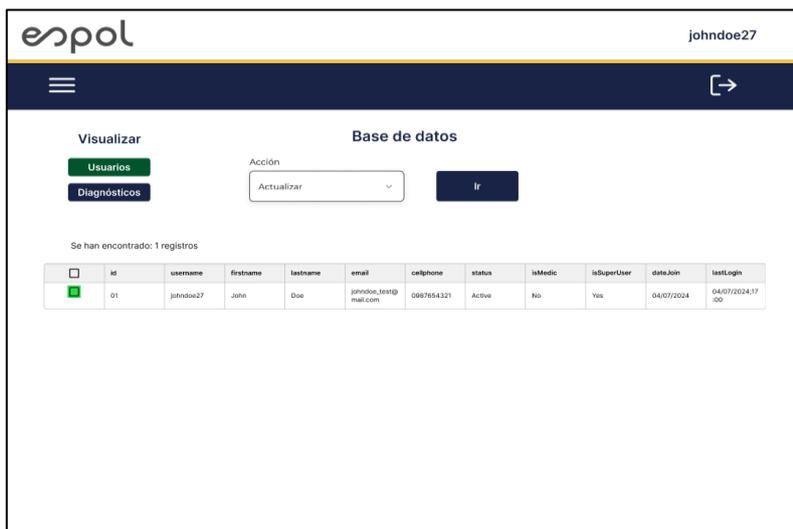


Figura 30

Vista de actualización de usuario (II)

The screenshot shows the 'Actualizar usuario' form in the espol system. The header includes the 'espol' logo and the user ID 'johndoe27'. A navigation bar contains a menu icon and a home icon. The form itself has a 'Volver' button and a title 'Actualizar usuario'. It contains several input fields: 'Nombre' (John), 'Apellidos' (Doe), 'Nombre de usuario' (johndoe27), 'Correo Electrónico' (johndoe27@mail.com), 'Teléfono' (0987654321), and 'Estado' (a dropdown menu with 'Seleccione un estado'). There are also radio buttons for 'Rol' with 'Medico' and 'Administrador' options, where 'Administrador' is selected. A green 'Actualizar información' button is at the bottom.

Figura 31

Vista de actualización de usuario (III)

This screenshot shows the same 'Actualizar usuario' form as in Figure 30, but with a confirmation dialog box overlaid. The dialog box is titled 'Confirmación' and contains the text: '¿Desea realizar la actualización de información para usuario "johndoe27"?'. It has two buttons: 'Cancelar' and 'Actualizar información'. The background of the form is dimmed.

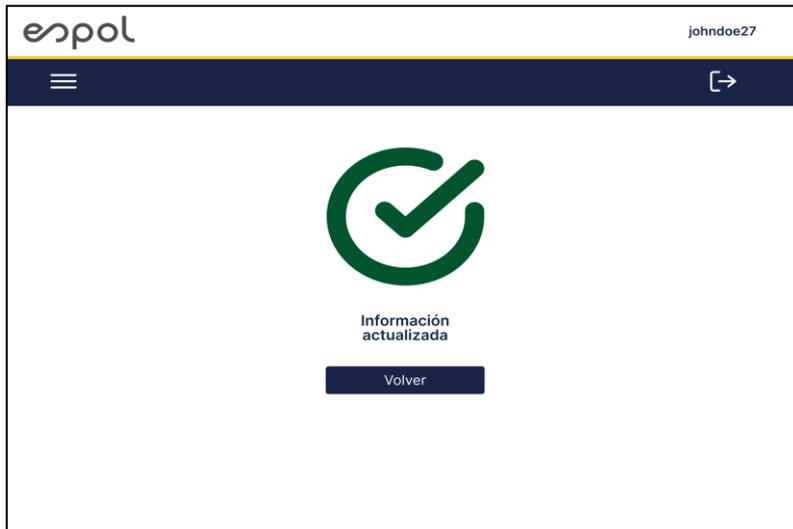
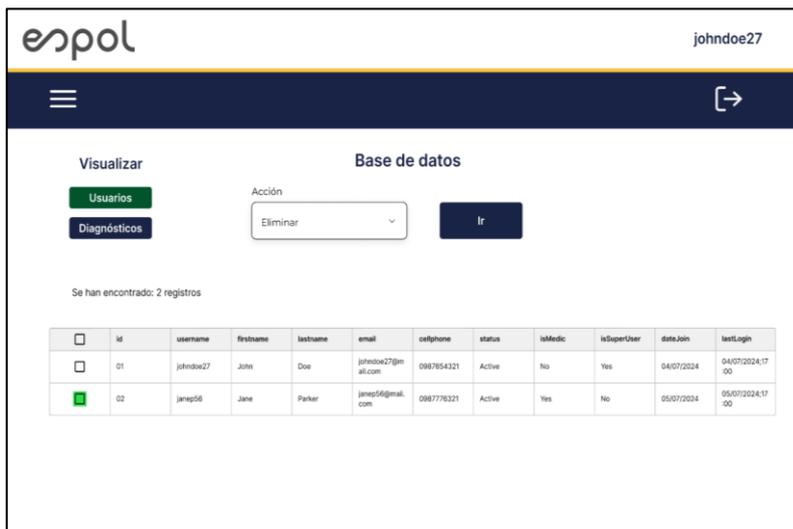
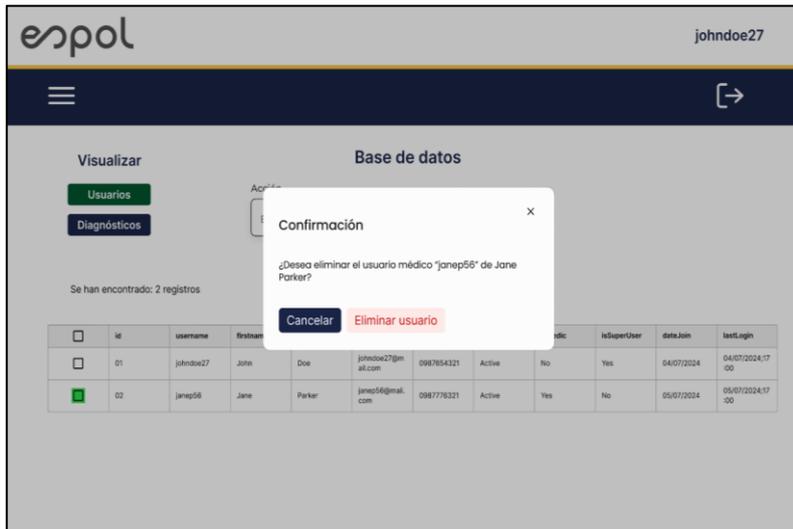
Figura 32*Vista de actualización de usuario (IV)***Figura 33***Vista de eliminación de usuario (I)*

Figura 34*Vista de eliminación de usuario (II)*

espol johndoe27

Visualizar Base de datos

Usuarios Diagnósticos

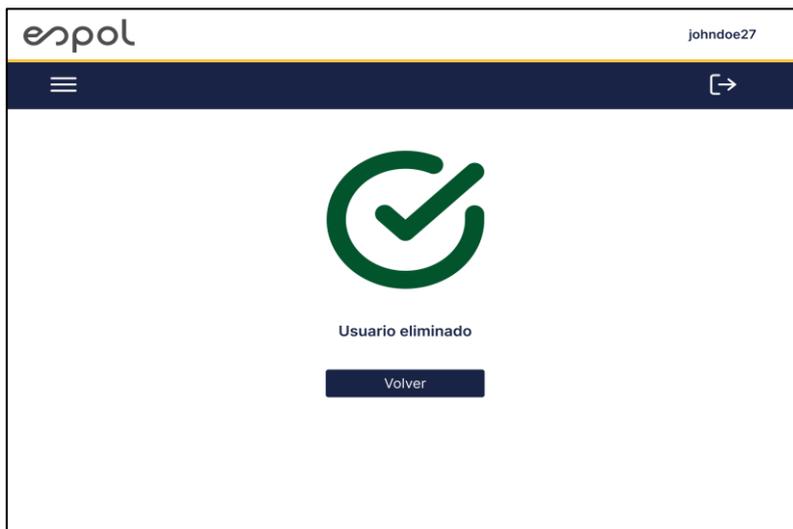
Se han encontrado: 2 registros

Confirmación

¿Desea eliminar el usuario médico "jane56" de Jane Parker?

Cancelar Eliminar usuario

<input type="checkbox"/>	id	username	firstnam	lastnam	email	phone	status	isSuperUser	dateJoin	lastLogin
<input type="checkbox"/>	01	johndoe27	John	Doe	johndoe27@espol.com	0987654321	Active	No	04/07/2024	04/07/2024:17:00
<input checked="" type="checkbox"/>	02	jane56	Jane	Parker	jane56@gmail.com	098776321	Active	Yes	05/07/2024	05/07/2024:17:00

Figura 35*Vista de actualización de usuario (III)*

espol johndoe27

Usuario eliminado

Volver

Apéndice C

Configuración del extractor de características PyRadiomics

```
{
    "minimumROIDimensions": 2,
    "minimumROISize": None,
    "normalize": True,
    "normalizeScale": 1,
    "removeOutliers": None,
    "resampledPixelSpacing": None,
    "interpolator": "sitkBSpline",
    "preCrop": False,
    "padDistance": 5,
    "distances": [1],
    "force2D": False,
    "force2Ddimension": 0,
    "resegmentRange": None,
    "label": 3,
    "additionalInfo": True,
    "firstorder": [
        "Energy",
        "TotalEnergy",
        "Entropy",
        "Minimum",
        "10Percentile",
        "90Percentile",
        "Maximum",
        "Mean",
        "Median",
        "InterquartileRange",
        "Range",
        "MeanAbsoluteDeviation",
        "RobustMeanAbsoluteDeviation",
        "RootMeanSquared",
        "Skewness",
        "Kurtosis",
        "Variance",
        "Uniformity",
    ],
    "shape": [
        "MeshVolume",
        "VoxelVolume",
        "SurfaceArea",
        "SurfaceVolumeRatio",
        "Sphericity",
        "Maximum3DDiameter",
        "Maximum2DDiameterSlice",
        "Maximum2DDiameterColumn",
        "Maximum2DDiameterRow",
        "MajorAxisLength",
        "MinorAxisLength",
        "LeastAxisLength",
        "Elongation",
        "Flatness",
    ],
    "glcm": None,
    "glrlm": None,
    "glszm": None,
    "gldm": None,
    "ngtdm": None,
}
```

Apéndice D

Resultados de clasificadores usando algoritmo de selección de características

Features	Classifier	Global F1 Score	True Negatives	False Positives	False Negatives	True Positives
KB_ANOVA_FV	Extra_Trees	0,94	0,51	0,04	0,02	0,43
P_ANOVA_FV	Extra_Trees	0,93	0,52	0,03	0,04	0,42
SFM_L1_SVC_Scl	Radom_Forest	0,92	0,49	0,05	0,03	0,42
NP	Radom_Forest	0,91	0,49	0,06	0,03	0,42
Scl	Radom_Forest	0,91	0,49	0,06	0,03	0,42
P_ANOVA_FV	Radom_Forest	0,91	0,50	0,05	0,04	0,41
SFM_LR_Scl	Radom_Forest	0,91	0,49	0,05	0,04	0,42
SFM_L1_SVC_Scl	Extra_Trees	0,91	0,49	0,05	0,04	0,42
RFE_LR	Radom_Forest	0,91	0,48	0,06	0,03	0,42
RFE_LR_Scl	Radom_Forest	0,91	0,48	0,06	0,03	0,42
SFM_LR_Scl	Extra_Trees	0,91	0,48	0,06	0,03	0,42
RFECV	Gaussian_Process_Classificati	0,91	0,49	0,06	0,04	0,42
NP	Extra_Trees	0,90	0,49	0,06	0,04	0,41
KB_ANOVA_FV	Radom_Forest	0,90	0,48	0,06	0,04	0,42
RFE_LR_Scl	Extra_Trees	0,90	0,48	0,06	0,04	0,42
RFECV	Radom_Forest	0,90	0,48	0,06	0,04	0,42
RFECV	Extra_Trees	0,90	0,48	0,06	0,04	0,42
Scl	Extra_Trees	0,89	0,48	0,07	0,04	0,42
RFE_LR_Scl	Gaussian_Process_Classificati	0,89	0,48	0,07	0,04	0,42
RFE_LR	Extra_Trees	0,89	0,47	0,07	0,04	0,42
RFE_LR_Scl	Decision_Trees	0,89	0,49	0,06	0,05	0,40
SFM_L1_SVC_Scl	Decision_Trees	0,89	0,49	0,05	0,06	0,39
P_ANOVA_FV	Gaussian_Process_Classificati	0,88	0,50	0,05	0,07	0,38