



Acta de Correcciones al Proyecto de Grado Ingeniería Biomédica

Fecha: 30 de enero de 2025

Autores: Sebastián Hurtado Bustos y Santiago Valencia Amaya

Nombre del Proyecto de Grado: Identificación automática de ataque cerebrovascular (ACV) isquémico mediante la aplicación de técnicas de Deep Learning en imágenes de tomografía computarizada

Director: Hernán Darío Vargas Cardona

Como indica el artículo 2.27 de las Directrices de Trabajo de Grado, he verificado que los estudiantes indicados arriba han implementado todas las correcciones que los Jurados del Proyecto de Grado definieron que se efectuaran, como consta en el Acta de Calificación correspondiente.

Hernán Darío
Vargas
Cardona

Firmado digitalmente
por Hernán Darío
Vargas Cardona
Fecha: 2025.01.30
08:49:12 -05'00'

Firma de Director(a) del Proyecto de Grado



Pontificia Universidad
JAVERIANA
Cali

**Facultad de Ingeniería
y Ciencias**

Ingeniería Biomédica

MONOGRAFÍA DE TRABAJO DE GRADO

Identificación automática de ataque cerebrovascular
(ACV) isquémico mediante la aplicación de técnicas de
Deep Learning en imágenes de tomografía
computarizada

Sebastián Hurtado Bustos
Santiago Valencia Amaya

Director

Dr. Hernán Darío Vargas Cardona

30 de enero de 2025

Santiago de Cali, 30 de enero de 2025

Señores
Pontificia Universidad Javeriana – Cali
Dr. Camilo Rocha Niño
Decano
Facultad de Ingeniería y Ciencias
Ciudad

Cordial Saludo.

Por medio de la presente nos permitimos presentarle el Trabajo de Grado titulado “Identificación automática de ataque cerebrovascular (ACV) isquémico mediante la aplicación de técnicas de Deep Learning en imágenes de tomografía computarizada”.

Esperamos que este trabajo reúna todos los requisitos académicos, cumpla el propósito para el cual fue creado y sirva de apoyo para futuros proyectos relacionados con la materia.

Atentamente,

Sebastián HB

Sebastián Hurtado Bustos

Santiago Valencia A.

Santiago Valencia Amaya

Santiago de Cali, 30 de enero de 2025

Señores

Pontificia Universidad Javeriana – Cali

Dr. Camilo Rocha Niño

Decano

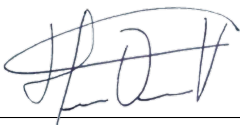
Facultad de Ingeniería y Ciencias

Ciudad

Cordial Saludo.

Certifico que el presente Trabajo de Grado titulado “Identificación automática de ataque cerebrovascular (ACV) isquémico mediante la aplicación de técnicas de Deep Learning en imágenes de tomografía computarizada”, realizado por Sebastián Hurtado Bustos y Santiago Valencia Amaya, estudiantes de Ingeniería Biomédica, se encuentra terminado y puede ser presentado para su sustentación.

Atentamente,



Dr. Hernán Darío Vargas Cardona
Director Trabajo de Grado

Agradecimientos

Queremos expresar nuestro más profundo agradecimiento a todas las personas que hicieron posible la realización de este trabajo de grado.

En primer lugar, a nuestras familias, quienes nos han brindado apoyo incondicional durante todo este proceso. Su comprensión, paciencia y confianza han sido fundamentales para superar los retos y alcanzar este logro, confiando en que seremos grandes profesionales.

Agradecemos también al laboratorista Lewis Riascos Mina, por su asistencia técnica y disposición a colaborar en cada etapa de este proyecto.

De manera especial agradecemos al equipo de trabajo en el área de radiología en la Fundación Valle del Lili, por su apoyo, enseñanza y guía tanto en la formación como ingeniero biomédico como en la realización de cada etapa del proyecto, su apoyo y guía fueron fundamentales para dar una base firme al desarrollo del proyecto y poder darle un enfoque acorde a lo que en realidad necesita el campo de la salud.

De manera especial, queremos reconocer al Dr. Hernán Vargas Cardona, quien ha desempeñado un doble rol como director de carrera y director de este trabajo de grado. Su guía, consejos y constante motivación nos permitieron dar lo mejor de nosotros y alcanzar los objetivos planteados.

Finalmente, agradecemos a la profesora Valentina Corchuelo y al profesor Juan Esteban Palacios, por su dedicación y apoyo académico a lo largo de nuestra formación. Su orientación fue un pilar clave en nuestro crecimiento profesional y en la culminación de este trabajo.

A todos, muchas gracias por haber sido parte de este camino, seremos unos excelentes profesionales gracias a la formación y apoyo de ustedes.

Glosario

Acrónimos y Abreviaturas

<i>ACV</i>	Accidente cerebrovascular
<i>CT</i>	Computed tomography
<i>NIHSS</i>	National Institutes of Health Stroke Scale
<i>CNN</i>	Convolutional Neural Network
<i>SVM</i>	Maquinas de soporte vectoriales
<i>KNN</i>	K-Nearest Neighbor
<i>DL</i>	Deep learning
<i>FSC</i>	Flujo sanguíneo cerebral
<i>ML</i>	Machine learning
<i>RBF</i>	Radial basis function
<i>NRRD</i>	Nearly Raw Raster Data
<i>RAS</i>	Sistema de coordenadas estándar
<i>DICOM</i>	Digital Imaging and Communications in Medicine
<i>RM</i>	Resonancia magnética

Resumen

El ataque cerebrovascular isquémico (ACV) ocurre cuando un coágulo de sangre bloquea una arteria del cerebro, llevando a una interrupción del flujo sanguíneo y privando a las células cerebrales de oxígeno y nutrientes, siendo la segunda causa de muerte a nivel mundial según la OMS y es de las primeras causas de discapacidad a largo plazo. Por otro lado, la desinformación es un factor importante que agrava la problemática, dando prioridad a trabajar en la concientización de este. El proyecto tiene como objetivo principal entrenar modelos para apoyo al diagnóstico que puedan ayudar a los profesionales de la salud a detectar de manera más rápida y precisa el ACV isquémico, lo que podría tener un impacto significativo en el tratamiento y la recuperación de los pacientes, así como en la reducción de los costos asociados y el impacto socioeconómico de esta enfermedad. Los modelos implementan técnicas de aprendizaje profundo basadas en redes neuronales convolucionales en 3 dimensiones (CNN3D) las cuales se usaron como extractores de características sobre estudios de tomografía computacional (CT). Luego de procesar el conjunto de datos con todos los modelos de deep learning, se aplicaron clasificadores SVM con los kernels lineal, RBF y polinomial utilizando Grid Search para ajustar hiperparámetros, KNN evaluado con 3 y 5 vecinos; Perceptrón Multicapa (MLP) y XGBoost. Para cada clasificador se realizaron 10 repeticiones con partición 70-30% (Hold-Out aleatorio), y se reportó el valor promedio \pm desviación estándar de la accuracy, Sensitivity, Specificity, F1-Score, y AUC-ROC. El esquema experimental permitió demostrar que las CNN 3D funcionan muy bien como extractores de información relevante en CT, para identificar automáticamente ACV.

Palabras Clave: ACV isquémico, redes neuronales convolucionales (CNN), clasificadores, Deep learning, procesamiento de imágenes, Tomografía Computacional (CT).

Abstract

The ischemic stroke (ACV) occurs when a blood clot blocks an artery in the brain, leading to an interruption of blood flow and depriving brain cells of oxygen and nutrients. It is the second leading cause of death worldwide according to the WHO and one of the main causes of long-term disability. On the other hand, misinformation is an important factor that worsens the issue, highlighting the need to prioritize awareness efforts regarding this condition.

The project's main objective is to train diagnostic support models that can help healthcare professionals detect ischemic strokes more quickly and accurately. This could have a significant impact on patient treatment and recovery, as well as on reducing associated costs and the socioeconomic burden of this disease. The models implement deep learning techniques based on three-dimensional convolutional neural networks (3D CNNs), which were used as feature extractors on computed tomography (CT) scans. After processing the dataset with all the deep learning models, SVM classifiers with linear, RBF, and polynomial kernels were applied using Grid Search for hyperparameter tuning, KNN evaluated with 3 and 5 neighbors, Multilayer Perceptron (MLP), and XGBoost. For each classifier, 10 repetitions were performed using a 70-30% random Hold-Out split, and the mean value \pm standard deviation of accuracy, sensitivity, specificity, F1-Score, and AUC-ROC were reported. The experimental scheme demonstrated that 3D CNNs perform very well as feature extractors in CT scans for the automatic identification of strokes.

Keywords: Ischemic Stroke, Convolutional Neural Networks (CNNs), Classifiers, Deep Learning, Image Processing, Computed Tomography (CT).

Índice general

1. Introducción	1
2. Planteamiento del Problema	3
3. Justificación	7
4. Objetivos	9
4.1. Objetivo General	9
4.2. Objetivos Específicos	9
5. Marco de Referencia	11
5.1. Áreas Temáticas	11
5.2. Marco Teórico	11
5.3. Trabajos Relacionados	27
6. Materiales y Métodos	29
6.1. Tipo de Estudio	29
6.2. Actividades	29
6.2.1. Especificaciones de modelos	35
6.3. Recursos	37
6.3.1. Técnicos	37
7. Resultados y Discusión	39
7.1. Resultados experimentales	39
7.1.1. ResNet-18 3D	39
7.1.2. ResNet-50 3D	46
7.1.3. DenseNet 3D	53
7.1.4. DeepMultiScale 3D	60
7.1.5. ICH 3D	67
7.2. Discusión general	73
8. Conclusiones	75
9. Trabajos futuros	77
10. Anexos	79

Anexos	79
Anexo 1 Acuerdo de Confidencialidad - Investigaciones Clínicas - Sebastián Hurtado Bustos	80
Anexo 2 – Acuerdo de Confidencialidad - Investigaciones Clínicas - Santiago Valencia Amaya	85
Anexo 3 – Acuerdo de Confidencialidad - Investigaciones Clínicas - Hernán Darío Vargas	
Cardona	92
Bibliografía	99

Índice de figuras

3.1. Optimización en diagnóstico derivado de la IA (Fuente: [1]).	8
5.1. Imagen de CT (Atrofia subcortical), (Fuente: [2]).	14
5.2. Funcionamiento de las CNN (Fuente:[3]).	15
5.3. Diagrama ResNet18 (Fuente:[4]).	16
5.4. Diagrama ResNet50 (Fuente:[5]).	17
5.5. Bloque denso y capa de transición DenseNet3D (Fuente:Propia).	18
5.6. Diagrama de DenseNet3D, con tasa crecimiento de 32 y filtros iniciales de 32, con una tasa de abandono de 0.4 (Fuente:Propia).	18
5.7. Diagrama Deep MultiScale 3D modificado (Fuente:Propia).	19
5.8. Diagrama de modelo ICH3D modificado (Fuente:Propia).	20
5.9. Funcionamiento SVM (Fuente: [6]).	21
5.10. Kernel linear (Fuente: [7]).	21
5.11. Kernel RBF (Fuente:[7]).	22
5.12. Kernel Polynomial (Fuente: [7]).	22
5.13. Funcionamiento KNN (Fuente:[8]).	23
5.14. Ejemplo KNN con K=3 y K=5 vecinos (Fuente: Propia).	23
5.15. Curva ROC (Salida del modelo de ejemplo) (Fuente: [9]).	26
5.16. Matriz de confusión y métricas calculadas a partir de esta (Fuente: [10]).	26
6.1. Diagrama de Preprocesamiento (Fuente: Propia).	31
7.1. Curva de loss y accuracy de ResNet-18 3D (Fuente: Propia).	40
7.2. Curva AUC-ROC y matriz de confusión de SVM lineal+ResNet-18 3D	40
7.3. Curva AUC-ROC y matriz de confusión de SVM RBF+ResNet-18 3D	41
7.4. Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ResNet-18 3D	42
7.5. Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ResNet-18 3D	42
7.6. Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+ResNet-18 3D	43
7.7. Curva AUC-ROC y matriz de confusión MLP+ResNet-18 3D	44
7.8. Curva AUC-ROC y matriz de confusión de XGBoost+ResNet-18 3D	44
7.9. Curva de loss y accuracy de ResNet-50 3D (Fuente: Propia).	46
7.10. Curva AUC-ROC y matriz de confusión de SVM lineal+ResNet-50 3D	47
7.11. Curva AUC-ROC y matriz de confusión de SVM RBF+ResNet-50 3D	47
7.12. Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ResNet-50 3D	48
7.13. Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ResNet-50 3D	49
7.14. Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+ResNet-50 3D	49
7.15. Curva AUC-ROC y matriz de confusión de MLP+ResNet-50 3D	50

7.16. Curva AUC-ROC y matriz de confusión de XGBoost+ResNet-50 3D	51
7.17. Curva de loss y accuracy DenseNet 3D (Fuente: Propia).	53
7.18. Curva AUC-ROC y matriz de confusión de SVM lineal+DenseNet 3D	54
7.19. Curva AUC-ROC y matriz de confusión de SVM RBF+DenseNet 3D	54
7.20. Curva AUC-ROC y matriz de confusión de SVM POLINOMIAL+DenseNet 3D	55
7.21. Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+DenseNet 3D	56
7.22. Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+DenseNet 3D	56
7.23. Curva AUC-ROC y matriz de confusión de MLP+DenseNet 3D	57
7.24. Curva AUC-ROC y matriz de confusión de XGBoost+DenseNet 3D	58
7.25. Curva de loss y accuracy de DeepMultiScale 3D (Fuente: Propia).	60
7.26. Curva AUC-ROC y matriz de confusión de SVM lineal+DeepMultiScale 3D	61
7.27. Curva AUC-ROC y matriz de confusión de SVM RBF+DeepMultiScale 3D	61
7.28. Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+DeepMultiScale 3D	62
7.29. Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+DeepMultiScale 3D	63
7.30. Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+DeepMultiScale 3D	63
7.31. Curva AUC-ROC y matriz de confusión de MLP+DeepMultiScale 3D	64
7.32. Curva AUC-ROC y matriz de confusión de XGBoost+DeepMultiScale 3D	65
7.33. Curva de loss y accuracy ICH 3D (Fuente: Propia)	67
7.34. Curva AUC-ROC y matriz de confusión de SVM lineal+ICH 3D	68
7.35. Curva AUC-ROC y matriz de confusión de SVM RBF+ICH 3D	68
7.36. Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ICH 3D	69
7.37. Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ICH 3D	70
7.38. Curva AUC-ROC y matriz de confusión de KNN5+ICH 3D	70
7.39. Curva AUC-ROC y matriz de confusión de MLP+ICH 3D	71
7.40. Curva AUC-ROC y matriz de confusión de XGBoost+ICH 3D	72

Índice de cuadros

7.1. Resultados del entrenamiento del modelo Resnet18-3D clasificando a partir de la capa final con la función de activación sigmoide.	39
7.2. Mejor accuracy de svm con kernel lineal+ResNet-18 3D	41
7.3. Mejor accuracy con los hiperparámetros $C = 0.1$ y $\text{Gamma} = 0.01$ de SVM RBF+ResNet-18 3D	41
7.4. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$, $\text{Degree} = 2$ de SVM POLYNOMIAL+ResNet-18 3D	42
7.5. Mejor accuracy de KNN 3 vecinos+ResNet-18 3D	43
7.6. Mejor accuracy de KNN 5 vecinos+ResNet-18 3D	43
7.7. Mejor accuracy de MLP+ResNet-18 3D, alcanzado en 30 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.	44
7.8. Mejor accuracy de XGBoost+ResNet-18 3D	45
7.9. Promedios y desviaciones estándar de las métricas de ResNet-18 3D	45
7.10. Resultados del entrenamiento del modelo ResNet-50 3D clasificando a partir de la capa final con la función de activación sigmoide	46
7.11. Mejor accuracy de svm con kernel lineal+ResNet-50 3D	47
7.12. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$ de SVM RBF+ResNet-50 3D	48
7.13. Mejor accuracy con los hiperparámetros $C = 0.1$, $\text{Gamma} = 0.001$, $\text{Degree} = 3$ de POLYNOMIAL+ResNet-50 3D	48
7.14. Mejor accuracy de KNN 3 vecinos+ResNet-50 3D	49
7.15. Mejor accuracy de KNN 5 vecinos+ResNet-50 3D	50
7.16. Mejor accuracy de MLP+ResNet-50 3D, alcanzado en 60 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.	50
7.17. Mejor accuracy de XGBoost+ResNet-50 3D	51
7.18. Promedios y desviaciones estándar de las métricas de ResNet-50 3D	51
7.19. Resultados del entrenamiento del modelo DenseNet 3D clasificando a partir de la capa final con la función de activación sigmoide	53
7.20. Mejor accuracy de svm con kernel lineal+DenseNet 3D	54
7.21. Mejor accuracy con los hiperparámetros $C = 100$, $\text{Gamma} = 0.01$ de SVM RBF+DenseNet 3D	55
7.22. Mejor accuracy los hiperparámetros $C = 1$, $\text{Gamma} = 0.1$, $\text{Degree} = 3$ de SVM POLINOMIAL+DenseNet 3D	55
7.23. Mejor accuracy de knn 3 vecinos+DenseNet 3D	56
7.24. Mejor accuracy de knn 5 vecinos+DenseNet 3D	57
7.25. Mejor accuracy de MLP+DenseNet 3D, alcanzado en 72 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.	57

7.26. Mejor accuracy de XGBoost+DenseNet 3D	58
7.27. Promedios y desviaciones estándar de las métricas de DenseNet 3D	58
7.28. Resultados del entrenamiento del modelo DeepMultiScale 3D clasificando a partir de la capa final con la función de activación sigmoide	60
7.29. Mejor accuracy de svm con kernel lineal+DeepMultiScale 3D	61
7.30. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$ de SVM RBF+DeepMultiScale 3D	62
7.31. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.1$, $\text{Degree} = 2$ de SVM POLYNOMIAL+DeepMultiScale 3D	62
7.32. Mejor accuracy de KNN 3 vecinos+Deep MultiScale-3D	63
7.33. Mejor accuracy de KNN 5 vecinos+Deep MultiScale-3D	64
7.34. Mejor accuracy de MLP+DeepMultiScale 3D, alcanzado en 166 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.	64
7.35. Mejor accuracy de XGBoost+DeepMultiScale 3D	65
7.36. Promedios y desviaciones estándar de las métricas de DeepMultiScale 3D	65
7.37. Resultados del entrenamiento del modelo ICH 3D clasificando a partir de la capa final con la función de activación sigmoide	67
7.38. Mejor accuracy de svm con kernel lineal+ICH-3D	68
7.39. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.001$ de SVM RBF+ICH 3D	69
7.40. Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.001$, $\text{Degree} = 2$ de SVM POLYNOMIAL+ICH 3D	69
7.41. Mejor accuracy de KNN 3 vecinos+ICH-3D	70
7.42. Mejor accuracy de KNN 5 vecinos+ICH-3D	71
7.43. Mejor accuracy de MLP+ICH 3D, alcanzado en 44 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.	71
7.44. Mejor accuracy de XGBoost+ICH 3D	72
7.45. Promedios y desviaciones estándar de las métricas ICH 3D	72

Introducción

La identificación automática del accidente cerebrovascular (ACV) isquémico en imágenes de tomografía computarizada (CT) mediante técnicas de Deep Learning (DL) se ha convertido en un campo de estudio crucial para el avance de la neurología, ya que esta patología es una de las principales causas de morbilidad y mortalidad a nivel mundial. El ACV representa la segunda causa de muerte en el mundo desde hace más de una década, con más de 17 millones de casos y alrededor de 6.5 millones de defunciones anuales, según la Organización Mundial de la Salud (OMS) [11], es importante señalar que el 80% de estos accidentes son isquémicos [12]. Además de la elevada mortalidad, el ACV es la principal causa de discapacidad a largo plazo, lo que implica no solo un desafío médico inmediato en la fase aguda, sino también un proceso extenso de rehabilitación y cuidado post-ictus. Esta situación afecta significativamente la calidad de vida de los pacientes y representa una carga social y económica, ya que la rehabilitación prolongada y el cuidado a largo plazo requieren una significativa inversión en recursos de salud [13].

En el contexto específico de Colombia, el ACV se encuentra dentro de las cinco principales causas de muerte, con aproximadamente 16.000 muertes anuales, según el reporte de estadísticas vitales del Departamento Administrativo Nacional de Estadística (DANE), con corte a 2021 [14], para 2023 tuvo una tasa de 32,45 fallecimientos por cada 100.000 habitantes, lo que representa un total de 16.946 muertes, de las cuales el 48% fueron hombres y el 52% mujeres [15]. Las regiones más afectadas por esta enfermedad son Bogotá, Antioquia y Valle del Cauca, donde se concentra el mayor número de decesos. Este panorama no solo refleja la gravedad del problema desde una perspectiva de salud pública, sino que también pone de relieve la necesidad urgente de mejorar los métodos de diagnóstico y tratamiento. Además, se debe considerar que el 70% de los pacientes que sufren un ACV presentan dos o más factores de riesgo, como hipertensión, diabetes y tabaquismo, lo que aumenta la complejidad de la atención médica [16]. La identificación temprana y precisa del ACV isquémico a través de tecnologías innovadoras como el Deep Learning podría mejorar significativamente la eficiencia del diagnóstico, reduciendo el tiempo de intervención y las complicaciones asociadas a un diagnóstico tardío. Esto no solo beneficiaría a los pacientes, sino que también aliviaría la carga económica sobre los sistemas de salud, permitiendo una distribución más eficiente de los recursos y un mejor manejo de los casos en los sistemas de atención.

Sin embargo, la identificación de ACV en imágenes médicas presenta diversos obstáculos. En primer lugar, al utilizar volúmenes de tomografía computarizada de cerebro, la carga computacional para entrenar los modelos es mucho mayor, generando limitaciones en cuanto a la profundidad que pueden tener los modelos y el tiempo de ejecución de cada entrenamiento. Por otro lado, la

disponibilidad de datos etiquetados es limitada, ya que se requiere un conjunto de datos amplio y etiquetado que incluya tanto imágenes con ACV como sin ACV, además, la variabilidad en las imágenes médicas en términos de calidad, resolución, orientación y poblaciones de origen, lo que dificulta la extracción de características y la definición de patrones para la detección del ACV [17] [18].

Por ende, para abordar estos problemas, se requiere la implementación de técnicas avanzadas de aprendizaje profundo, específicamente mediante el uso de redes neuronales convolucionales (CNN), para identificar de manera dinámica casos de ACV isquémico en imágenes de tomografía computarizada (CT). En este trabajo se gestiona y procesa una base de datos de imágenes CT que abarca tanto casos de ACV isquémico como casos normales, con el propósito de entrenar algoritmos de aprendizaje automático. Se realizará una revisión de los modelos de aprendizaje profundo seleccionados, los cuales son ResNet-18 3D, ResNet-50 3D, DenseNet 3D, DeepMultiScale 3D e ICH 3D. A lo largo del informe, se describen las modificaciones implementadas en las arquitecturas para mejorar su rendimiento en función de los datos y la capacidad de cómputo disponible. Posteriormente, se utilizan las características extraídas por cada modelo entrenado para implementar diferentes clasificadores, logrando probar diferentes algoritmos a un menor costo computacional que permitieron ampliar la cantidad de pruebas y buscar un mejor resultado. Por último, se evalúa el rendimiento de estas técnicas de aprendizaje profundo y automático utilizando métricas de clasificación ampliamente reconocidas en la literatura, con el objetivo de identificar el modelo adecuado para la identificación de ACV isquémico.

Planteamiento del Problema

El ACV es la segunda causa de muerte a nivel mundial en estos últimos 15 años, así lo reconoce la Organización Mundial de la Salud (OMS), ya que anualmente presenta 17 millones de casos y 6,5 millones de defunciones [11]. Aparte se debe tener en cuenta que es la primera causa de discapacidad a largo plazo, lo cual lleva a un proceso de rehabilitación tras superar la fase aguda del ataque, incrementando la carga económica para los sistemas de salud y la sociedad. Según el Centro nacional para la prevención de las enfermedades crónicas y la promoción de la salud (CDC), en los Estados Unidos se determinó que el 70 % de los pacientes con ACV presentan dos o más factores de riesgo, los cuales están cada vez más presentes debido al crecimiento de la población y el envejecimiento global que ha demostrado el problema socioeconómico que genera y el aumento de pacientes con estenosis de la arteria carótida interna asintomática [16], por ende, se estima que las muertes y la incapacidad por esta enfermedad serán más del doble en el 2030. En otras palabras, el ACV es una de las diez causas más importantes del aumento de los años de vida ajustados por discapacidad (AVAD) entre 1990 y el 2019, confirmado por el estudio de la Carga Global de Enfermedades, Lesiones y Factores de Riesgo (GBD) [19].

En Latinoamérica, esta enfermedad presenta una incidencia menor que la de Europa y Asia, con 35-183 casos por 100.000 habitantes. En Colombia, particularmente, se diagnostica en 45.000 personas cada año, con una incidencia anual de 88,9 casos por cada 100.000 habitantes, siendo mayor en el género masculino, una prevalencia de 19,9/1000 y una mortalidad de 16,27/100.000, lo cual ubica a esta enfermedad como la cuarta causa de muerte en el país [19]. Entrando específicamente en regiones de Colombia, el accidente cerebrovascular se ubica dentro de las cinco principales causas de muerte con casi 16.000 muertes anuales por la enfermedad (15.983), siendo Bogotá, Antioquia y Valle del Cauca en donde se registra el mayor número de decesos, según el reporte de estadísticas vitales del Dane, con corte a 2021 [14].

En cuanto a relación de una enfermedad con otras, se ve como la Neurosífilis meningovascular, causa accidentes cerebrovasculares en pacientes jóvenes, aumentando el impacto que tiene el ACV ya que esta población es la que menos se ve afectada, esto se evidencia en que menos del 5% de los casos a nivel mundial son en jóvenes, representando un reto diagnóstico debido a las múltiples etiologías posibles, entre ellas las infecciones [20] [21]. Del 15% al 40% de los pacientes con sífilis no tratada pueden desarrollar sífilis terciaria con manifestaciones principalmente neurodestructivas, descritas en la sífilis tardía, pero con meningitis crónica y accidente cerebrovascular de tipo meningovascular en su fase temprana, aquí es cuando se ve que los jóvenes pueden obviar un poco esa enfermedad, pero no significa que no la puedan desarrollar a causa de una enfermedad alterna[22]

[23].

El ataque o accidente cerebrovascular tiene un factor muy importante que lo define, este factor es el tiempo, ya que cada segundo al que no le llega sangre y oxígeno al cerebro puede causar un daño en alguna zona específica del cerebro, se debe entender que el deterioro de un tejido afecta a su alrededor y esto se conoce como penumbra isquémica, básicamente ese tejido en riesgo es parte del cerebro que va a morir si no se reabre el vaso sanguíneo y esto es lo que lleva a la importancia del tiempo en el tratamiento. Mientras más rápido se reabre el vaso sanguíneo, mejores chances tiene el paciente. Se deben tener en cuenta los dos tipos de accidentes cerebrovasculares, que son:

- **Accidente cerebrovascular isquémico:** este ocurre cuando los vasos sanguíneos del cerebro se bloquean.
- **Accidente cerebrovascular hemorrágico:** este ocurre cuando un vaso sanguíneo en cerebro se rompe o presenta una fuga.

Hay muchos factores de riesgo que las personas pueden tener y por lo cual son más propensas a sufrir un ACV, estos factores están relacionados con el estilo de vida, las enfermedades, la edad, la raza y el sexo, teniendo en cuenta estos, se puede analizar que la tasa de mayor prevalencia del ACV, se presenta en personas de 55 años en adelante, también que hay más casos de hombres que mujeres y que las personas afroamericanas e hispanas son más propensas a esos ataques, a todo esto se le suman riesgos médicos como colesterol alto, hipertensión arterial, diabetes, etc. Por eso el cuidado de la salud del paciente en el pasado y la actualidad, juega un papel tan importante en este análisis [24].

Algunas complicaciones que se pueden presentar por el ACV son:

- Parálisis o pérdida del movimiento muscular.
- Dificultad para hablar y tragar.
- Problemas emocionales, cambios en la conducta y en la capacidad de cuidado personal.
- Pérdida de memoria o dificultad para pensar.

En cuanto a tratamientos el más importante es, sin duda, la aparición de técnicas endovasculares más eficaces. Los pacientes con los accidentes cerebrovasculares más graves que tienen oclusiones en las principales arterias del cerebro pueden salvarse con un tratamiento denominado trombectomía mecánica con catéter, lo que se hace es eliminar el coágulo y también, se tiene como tratamiento primario la trombólisis intravenosa, administrada dentro de las primeras 4 horas y media [24].

Siguiendo con la idea de tratamientos, se debe saber que el mejor tratamiento contra enfermedades es evitarlas, los hábitos saludables son una barrera contra las enfermedades, el hecho de fumar, beber, consumir drogas, obesidad, falta de actividad física y no llevar un control del sistema cardiovascular, pueden ser factores que, al corregirlos, pueden evitar un deterioro a nivel cerebral. Ya en

el momento de realizar una primera intervención, en el ACV, se puede suministrar medicamentos antiplaquetarios y anticoagulantes.

En la detección de ACV en imágenes médicas se presentan diferentes obstáculos que dificultan la realización de esta tarea, los obstáculos que se presentan son los siguientes:

- **Pocos datos etiquetados:** el modelo de machine learning requiere entrenamiento donde se necesitan grandes conjuntos de datos etiquetados que incluyan imágenes sin ACV y con ACV. Se debe tener en cuenta que la recopilación de estos datos puede ser costosa y requiere de aprobación ética [25].
- **Variabilidad de imágenes:** debido a los formatos de imágenes en cuanto a calidad, resolución, orientación y las poblaciones de las cuales se extraen, las imágenes médicas pueden variar significativamente, por ende, para la extracción de características discriminantes y la definición de patrones para la detección, se dificultan [17].
- **Interpretación clínica:** para el entrenamiento de una red neuronal y definir sus parámetros, las imágenes que se van a utilizar debe ser validadas por un profesional en esa área, que tenga el conocimiento y experiencia clínica. Por otra parte, la variabilidad que hay entre observadores puede llevar a complicaciones en los entrenamientos de estas redes, por lo cual podría pasar por alto algunos parámetros importantes en la detección precisa del ACV [18].
- **El intercambio de algoritmos y la obtención de datos de imágenes anónimas:** puede ser un paso muy importante para el éxito del análisis en imágenes médicas, ya que se necesitan probar métodos desarrollados recientemente, pero la falta de datos que hay por la privacidad que se tiene en las instituciones genera una barrera para la evolución del rendimiento de estos nuevos métodos, por lo cual los métodos no se generalizan y se presentan dificultades para analizar diferentes poblaciones [26].

La introducción de la inteligencia artificial en la medicina representa un desafío para el campo, pero también promete transformar la educación médica y aumentar la demanda de profesionales en el área. La utilización de la IA en la interpretación de imágenes neurológicas y tratamientos prehospitalarios, tiene el potencial de reducir los retrasos en el diagnóstico y tratamiento, mejorando la atención al paciente [1].

Justificación

El ataque cerebrovascular (ACV) constituye la segunda causa de mortalidad y la primera de discapacidad en Colombia, lo que lo convierte en uno de los problemas que más afecta a la población, pero debemos tener en cuenta que ACV isquémico es el más común, ya que se estipula que un 80% de los ataques son por isquemia, por ende, el estudio que se realizará será entono a este tipo de ataque. En este sentido, se ha priorizado esta problemática en el sector de la salud. En términos numéricos, se estima que cada año se presentan alrededor de 16.000 muertes debido a esta enfermedad en Colombia. Cabe destacar que esta situación no solo se da en Colombia, sino que el ACV es la principal causa de discapacidad en el mundo [15]. La búsqueda inmediata de atención médica y el reconocimiento temprano de los signos de un ataque cerebral pueden reducir considerablemente las posibilidades de muerte y discapacidad. Es esencial actuar con rapidez, ya que por cada minuto de su evolución se pierden 2,03 millones de neuronas. Se estima que uno de cada cuatro adultos podría sufrir un ACV en algún momento de su vida [27].

Para el reconocimiento rápido y externo del ACV, se utilizan métodos como las escalas neurológicas en patología vascular cerebral, mediante las cuales se puede cuantificar la gravedad del ictus, su progresión y desenlace. En la fase aguda del ictus isquémico tanto su inicio como evolución, se utiliza la escala NIHSS (National Institutes of Health Stroke Scale), por otro lado para la valoración y seguimiento de la hemorragia subaracnoidea, se emplea la escala de Hunt y Hess [28].

Estos factores son esenciales para evaluar el momento en el que se manifestaron los síntomas, dado que dicho aspecto resultará crucial en el deterioro cerebral de la persona. Por lo tanto, es fundamental concientizar e informar a la población sobre estos procesos, ya que se puede disminuir un deterioro que puede ser permanente en la vida de los pacientes. El estudio de estas variables y síntomas nos dará una idea de cómo estructurar el sistema de detección por medio de algoritmos aplicados a las imágenes cerebrales obtenidas en la tomografía computarizada, lo cual busca ser incorporado en la ruta que se debe seguir para dar un diagnóstico óptimo sobre el paciente. Debemos enfocarnos en una población que presenta obesidad, presión arterial alta, colesterol alto, diabetes y, claramente, casos reincidentes de ACV, ya que son los más propensos a sufrir estos [29].

La información para la prevención y la toma de acción en caso de ACV en la población, así como la falta de conocimiento para detectarlo, fue proporcionada por Óscar Echeverry, quien se desempeña como coordinador del Hospital Simulado en la Pontificia Universidad Javeriana Cali [30]. Él hizo énfasis en el panorama que tiene el ACV en Colombia y su fuerte impacto debido al desconocimiento, y nos recomendó buscar una futura solución.

Se debe tener en cuenta que el nivel que un hospital o clínica necesita para atender un caso de estos es nivel 4 y que el sector de salud en Colombia no cuenta con estos niveles en todas las instituciones. Por lo tanto, la detección por medio de técnicas de DL tendrá un impacto a favor del beneficio de las comunidades que no cuentan con centros de salud cercanos con los niveles requeridos ya que el diagnóstico al ser más rápido disminuiría la ventana de riesgo. La mejora que presenta la inteligencia artificial sobre el proceso de diagnóstico es notable, esto se puede observar en el siguiente esquema:

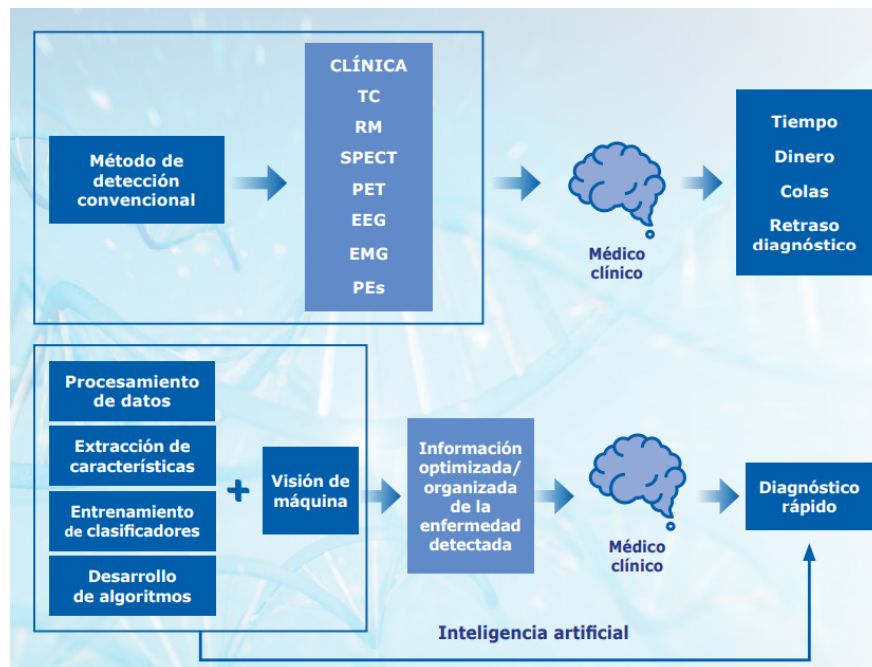


Figura 3.1: Optimización en diagnóstico derivado de la IA (Fuente: [1]).

Como se puede observar en la Figura 3.1, el método convencional de detección implica realizar pruebas según la modalidad necesaria, las cuales son analizadas por un médico. Sin embargo, este enfoque presenta dificultades que retrasan la identificación del problema. En contraste, la IA procesa la imagen, extrae la información relevante y la presenta de manera ordenada, brindando un valioso apoyo al médico para agilizar el proceso de diagnóstico.

Se ha demostrado que la detección temprana de ACV es fundamental para mejorar la eficacia de los tratamientos y reducir la tasa de mortalidad, por ende es importante resaltar que la IA ha evolucionado en el reconocimiento de patologías en imágenes neurológicas, influyendo de manera positiva en un diagnóstico preciso y en la mejora del flujo de trabajo, permitiendo obtener resultados rápidos y seguros [31].

Objetivos

4.1. Objetivo General

- Identificar automáticamente el ACV isquémico en imágenes CT mediante técnicas de Deep Learning para el soporte al diagnóstico.

4.2. Objetivos Específicos

1. Gestionar una base de datos de imágenes CT que contenga casos de ACV isquémico y casos normales para el entrenamiento de los algoritmos de aprendizaje.
2. Implementar técnicas de aprendizaje profundo basada en redes neuronales convolucionales (CNN) que permitan identificar ACV isquémico en imágenes CT.
3. Evaluar el rendimiento de las técnicas de DL empleando métricas de clasificación establecidas en la literatura de modo que se establezca el mejor modelo.

Marco de Referencia

5.1. Áreas Temáticas

- Procesamiento digital de imágenes médicas.
- Soporte al diagnóstico.
- Aprendizaje de máquina(Machine Learning).
- Evaluacion de modelos.

5.2. Marco Teórico

- **Bases Teóricas:** el cerebro es el centro de mando que rige todo el cuerpo, por ende una falla en su funcionamiento desencadena un desastre para todos los sistemas del cuerpo humano, claramente van a haber variaciones, dependiendo de la parte del cerebro en la que se ejecute el daño y la causa de este, con esto se puede dar paso a el ataque cerebrovascular, para abarcar todo lo que rodea este ataque debemos tener conocimientos sobre los tipos de ataque, enfocándonos en el ataque cerebrovascular isquémico, sus síntomas, causas, formas de diagnóstico y los tratamientos que se deben aplicar, esto dará paso al desarrollo de la forma de diagnóstico que se implementara para entender y elaborar el proyecto.
- **ACV:** se define a un accidente cerebrovascular o ataque cerebral como la detención del flujo sanguíneo a parte del cerebro. Al tener esta interrupción de irrigación sanguínea, las células cerebrales no pueden recibir el oxígeno y nutrientes que necesitan y comienzan a morir en minutos. Esto puede causar un daño severo al cerebro, discapacidad permanente e incluso la muerte [32].

Tipos de ACV: tenemos dos tipos de ACV de los cuales se despliegan otros grupos dependiendo de la zona afectada, los síntomas y las complicaciones que presenta, entonces tenemos.

- **Ataque Cerebrovascular isquémico:** este ocurre cuando los vasos sanguíneos del cerebro se bloquean o estrechan lo que causa una notoria reducción del flujo sanguíneo. La oclusión de un vaso arterial se da debido a la acumulación de depósitos de grasa o de coágulos sanguíneos u otros desechos que se desplazan por la sangre (con más frecuencia desde el corazón) y se alojan en los vasos sanguíneos del cerebro. El ataque cerebrovascular isquémico, puede ser transitorio, en este caso presentaría una oclusión transitoria que

después se resolverá por mecanismos del cuerpo, causando daños momentáneos [24]. Se debe entender que el flujo sanguíneo cerebral (FSC) está determinado por la resistencia vascular cerebral, que se relaciona directamente con su diámetro, este proceso permite que el FSC se mantenga constante a pesar de variaciones en la presión de perfusión. La sostenibilidad del FSC ocurre dentro de un rango de presión arterial media de 60 a 150 mmHg. Fuera de este rango, el cerebro no puede compensar los cambios en la presión de perfusión, ya que aumenta el riesgo de isquemia a bajas presiones y edema a altas presiones. Este flujo sanguíneo y la presión de perfusión cerebral se reducen por el ACV isquémico. En una primera etapa, el FSC puede ser periódico debido a la dilatación máxima que presentan las arterias y arteriolas, lo que provoca un aumento compensatorio en el volumen sanguíneo cerebral. En la siguiente, la vasodilatación máxima se termina, por ende, la fracción de extracción de oxígeno se incrementa para conservar la oxigenación y el metabolismo del tejido cerebral. Finalmente la isquemia supera el rango de autorregulación, lo que lleva a la disminución del FSC hasta que la circulación colateral falla, ocasiona la muerte celular [33] [34].

Los ACV isquémicos pueden ser de dos tipos:

- **Trombótico:** se produce cuando se forma un coágulo de sangre en una arteria del cerebro, generalmente debido a la acumulación de placa en las paredes arteriales [35].
 - **Embólico:** se produce cuando un coágulo de sangre se forma en otra parte del cuerpo y viaja a través del torrente sanguíneo hasta el cerebro, donde bloquea una arteria [35].
 - **Ataque cerebrovascular hemorrágico:** este ocurre cuando un vaso sanguíneo en el cerebro se rompe. estas hemorragias cerebrales pueden ser el resultado de muchas afecciones como presión arterial alta no controlada, sobretratamiento con anticoagulantes, depósitos de proteína en las paredes de los vasos sanguíneos que provocan debilidad en la pared del vaso y por el mismo ACV isquémico [36].
- **Causas:** la prevención y el cuidado propio son fundamentales para evitar los ataques cerebrovasculares. Algunos factores que pueden llevar a un ACV incluyen enfermedades como hipertensión arterial, colesterol alto, diabetes y antecedentes de ACV. El estilo de vida también juega un papel importante, como el sobrepeso, la falta de actividad física, el consumo excesivo de alcohol y drogas. Además, las personas afroamericanas e hispanas, así como los hombres mayores de 55 años, tienen un mayor riesgo. El uso de píldoras anticonceptivas y terapias hormonales que contienen estrógeno también puede ser un factor de riesgo [24].
 - **Síntomas:** una persona puede sufrir un ACV y no darse cuenta hasta después de unas horas por ende estar pendientes de las señales es muy importante. Los síntomas que se presentan son [37]:
 - Deficiencia motora unilateral o bilateral (incluida la falta de coordinación)
 - Deficiencia sensitiva unilateral o bilateral

- Apraxia de aparición aguda
 - Ataxia de inicio agudo
 - Déficit de percepción de presentación aguda
 - Afasia o disfasia (habla no fluida)
 - Hemianopsia (deficiencia visual en uno de los hemisferios visuales)
 - Desviación conjugada de la mirada
- **Riesgos** por la isquemia se desencadenan una serie de cambios fisiológicos y químicos que dañan la célula, estos conducen a la muerte celular por apoptosis o por necrosis, la apoptosis predomina en el área de penumbra isquémica y la necrosis en el centro del infarto. Todo esto conlleva ciertas complicaciones que dependiendo de la zona afectada y el tratamiento pueden predominar o diluirse [24].
- **Tratamientos** La circulación colateral se reconoce como vía fisiológica que preserva el cerebro contra la lesión isquémica y previene potencialmente el efecto de una arteria bloqueada, lo cual va definiendo el crecimiento de la lesión. Estando presentes para la perfusión colateral, la transformación hemorrágica, recanalización arterial, la reperfusión, y los resultados neurológicos después del accidente cerebrovascular [38]. Se tiene que hay una zona de infarto y a su alrededor de acuerdo con factores hemodinámicos se puede tener suficiente flujo sanguíneo residual para mantener la viabilidad celular, aunque no su función normal, durante un determinado tiempo que dependerá del tamaño de la perfusión residual. En esta zona denominada transitoriamente viable llamada área de penumbra isquémica es susceptible de recuperación si se corrigen la hipoperfusión y las alteraciones por ende es la diana de las medidas terapéuticas dirigidas a reducir la lesión y las secuelas tras la isquemia cerebral focal [33] [39].
- **Tomografía Computarizada:** la tomografía computarizada (CT) es una tecnología de diagnóstico por imágenes que utiliza un equipo especial de rayos X para crear imágenes transversales del cuerpo. Durante el procedimiento de CT, el paciente se mantiene inmóvil en una mesa que se mueve lentamente a través de una máquina de rayos X de gran tamaño. El procedimiento es indoloro y, en algunos casos, se puede administrar un tinte de contraste al paciente para mejorar la visualización de ciertas partes del cuerpo en las imágenes [40]. En la siguiente figura 5.1, se observa un ejemplo como queda una imagen de CT.




Figura 5.1: Imagen de CT (Atrofia subcortical), (Fuente: [2]).

- Machine learning:** el machine learning, o aprendizaje automático en español, es una rama de la inteligencia artificial (IA) que se enfoca en desarrollar algoritmos y modelos computacionales que permiten a las máquinas “aprender” a partir de datos y mejorar su desempeño en tareas específicas sin ser programadas explícitamente para cada caso. En lugar de seguir reglas y algoritmos codificados manualmente, el machine learning permite a las máquinas identificar patrones, aprender de ellos y hacer predicciones o tomar decisiones basadas en esos patrones. Para ello, se utilizan algoritmos que se ajustan automáticamente a partir de datos de entrenamiento, y que son capaces de mejorar su rendimiento a medida que se les alimenta con más datos [41]. El machine learning tiene una amplia gama de aplicaciones, como reconocimiento de imágenes, procesamiento del lenguaje natural, recomendación de productos, detección de fraudes, diagnóstico médico, entre otros. Además, se utiliza en diversas industrias, como la medicina, la tecnología, las finanzas, la publicidad, la agricultura, la manufactura y más [42].
- Deep Learning:** el aprendizaje profundo, que constituye una subdivisión del aprendizaje automático, se define esencialmente como una red neuronal con tres o más capas. Estas redes neuronales buscan imitar el funcionamiento del cerebro humano, aunque distan de igualar su capacidad, posibilitándoles “aprender” a partir de extensas cantidades de datos. Mientras que una red neuronal con una sola capa puede realizar predicciones aproximadas, la incorporación de capas ocultas adicionales resulta fundamental para mejorar y afinar la precisión del proceso [3].

- **Redes neuronales:** ampliamente utilizados en investigaciones educativas, para determinar el orden de importancia de las variables predictoras, continuas y discretos, sobre conjuntos de datos reales y de simulación de diferentes tamaños de muestra. Se utilizan datos de simulación generados al considerar las relaciones en estos conjuntos de datos. Se utilizan sesgos relativos absolutos y errores cuadráticos medios (ECM) para comparar el rendimiento de los métodos [43].

Las redes neuronales artificiales son modelos matemáticos que pueden ser entrenados para aprender relaciones no lineales entre un conjunto de datos de entrada y un conjunto de datos de salida. En medicina la aplicación más común de estos modelos es la clasificación de patrones con el propósito de apoyar al médico en el diagnóstico y tratamiento del paciente [44].

- **Redes neuronales convolucionales:** las Convolutional Neural Networks (CNN), usadas principalmente en aplicaciones de clasificación de imágenes, son un tipo de Red Neuronal Artificial con aprendizaje supervisado. Estas redes están diseñadas para procesar sus capas de manera similar al cortex visual del ojo humano, permitiéndoles identificar distintas características en las entradas. En esencia, las CNN pueden “ver” y reconocer objetos al imitar el proceso de percepción visual. La arquitectura de una CNN incluye varias capas ocultas especializadas que forman una jerarquía: las primeras capas pueden detectar líneas y curvas, y a medida que se avanza en las capas, la red se especializa cada vez más, llegando a reconocer formas complejas en las imágenes [3] [45].

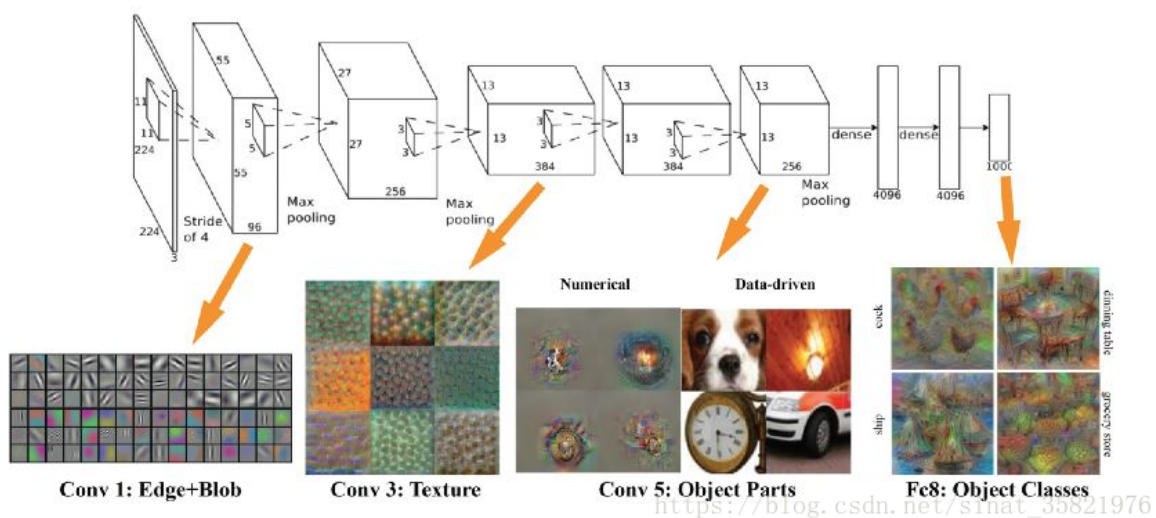


Figura 5.2: Funcionamiento de las CNN (Fuente:[3]).

- **Arquitecturas de CNN.**

- **ResNet (Residual Network):** una Red Neural Residual (ResNet) es una Red Neural Artificial (ANN) utilizada para tareas como el reconocimiento de imágenes.

ResNet fue mencionado por primera vez en el artículo de 2015 Deep Residual Learning for Image Recognition por los creadores Kaiming He, Xiangyu Zhang, Shaoqing Ren y Jian Sun. ResNet [46] resuelve este problema de degradación del rendimiento o pérdida de gradiente. Las redes neuronales residuales ResNet son un tipo especial de red neuronal, ANN. ResNet es una versión extendida de las redes neuronales porque ambas contienen capas de activación de la función BatchNormalization de bloques convolucionales [4], pero ResNet también contiene bloques residuales además de esto, a medida que se añaden más capas a una red neuronal, el rendimiento no necesariamente mejora y puede incluso empeorar. Las ResNet abordan este problema mediante el uso de conexiones residuales o atajos (skip connections) que permiten que la información se salte una o más capas.

1. **ResNet-18:** esta red neuronal que se usó como fundamento, se centra en la detección de la Enfermedad de Alzheimer (EA) utilizando el modelo ResNet-18 en Resonancia Magnética (RM). y en este estudio, se investigó el rendimiento de ResNet 18 para la detección de EA [4]. El número “18” de la red se refiere a la profundidad del modelo. La profundidad de la red se describe como el mayor número de capas convolucionales secuenciales y capas totalmente conectadas en una pista desde la primera capa hasta la última capa como se muestra en la figura 5.3.




Figura 5.3: Diagrama ResNet18 (Fuente:[4]).

2. **ResNet-50:** es la base de mucha investigación académica en este campo. Muchos artículos diferentes compararán sus resultados con una línea base de ResNet 50, y es valioso como punto de referencia. Para la mayoría de los problemas, este es el mejor enfoque para comenzar, en lugar de tratar de inventar nuevas redes o técnicas, construir un conjunto de datos personalizado y ampliarlo con técnicas de aumento de datos lo llevará mucho más allá de tratar de construir una nueva arquitectura [5].

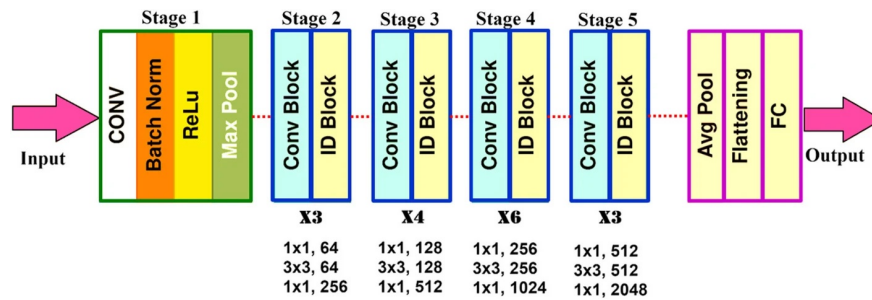


Figura 5.4: Diagrama ResNet50 (Fuente:[5]).

- **DenseNet 3D:** la estructura del modelo DenseNet 3D consta de una capa convolucional, 4 bloques densos, 3 capas de transición, una capa de agrupamiento global promedio, una capa de dropout y una capa final Dense con activación sigmoid para la clasificación binaria. Primero, se agrega una capa convolucional después de la capa de entrada con un paso de $2 \times 2 \times 2$, seguida de 4 bloques densos [47]. El bloque denso utiliza una conectividad densa, a través de la cual la L -ésima capa recibe los mapas de características de salida de todas las capas anteriores. Esta conectividad se representa como $[X_0, X_1, \dots, X_{l-1}]$, donde $[X_0, X_1, \dots, X_{l-1}]$ es la concatenación de los mapas de características de todas las capas anteriores en un único tensor [48], y HL denota una función de transformación no lineal compuesta de cuatro operaciones consecutivas: normalización por lotes, unidades lineales rectificadas con fugas, convolución $3 \times 3 \times 3$, y abandono. En cada bloque denso, cada capa densa recibe los mapas de características de todas las capas densas anteriores mediante una conexión de acceso directo [49]. La capa densa incluye una capa convolucional $1 \times 1 \times 1$ y una $3 \times 3 \times 3$, dos capas de normalización por lotes y dos capas de activación. Los bloques densos contienen dos capas densas. Entre dos bloques densos, se establece una capa de transición para lograr la reducción de la dimensión de los mapas de características. Consiste en cinco operaciones consecutivas: normalización por lotes, unidades lineales rectificadas con fugas, una convolución $1 \times 1 \times 1$, abandono (dropout), y una convolución $3 \times 3 \times 3$ con un paso de $2 \times 2 \times 2$, en la figura 5.5, se ilustra la estructura de estos bloques [47]. Después del último bloque denso, se realiza una operación de agrupamiento global promedio (global average pooling), seguida de una capa de abandono (dropout). La clasificación final se realiza con una capa Dense utilizando activación sigmoid para resolver el problema de clasificación binaria. En la figura 5.6, se ilustra la estructura del modelo.

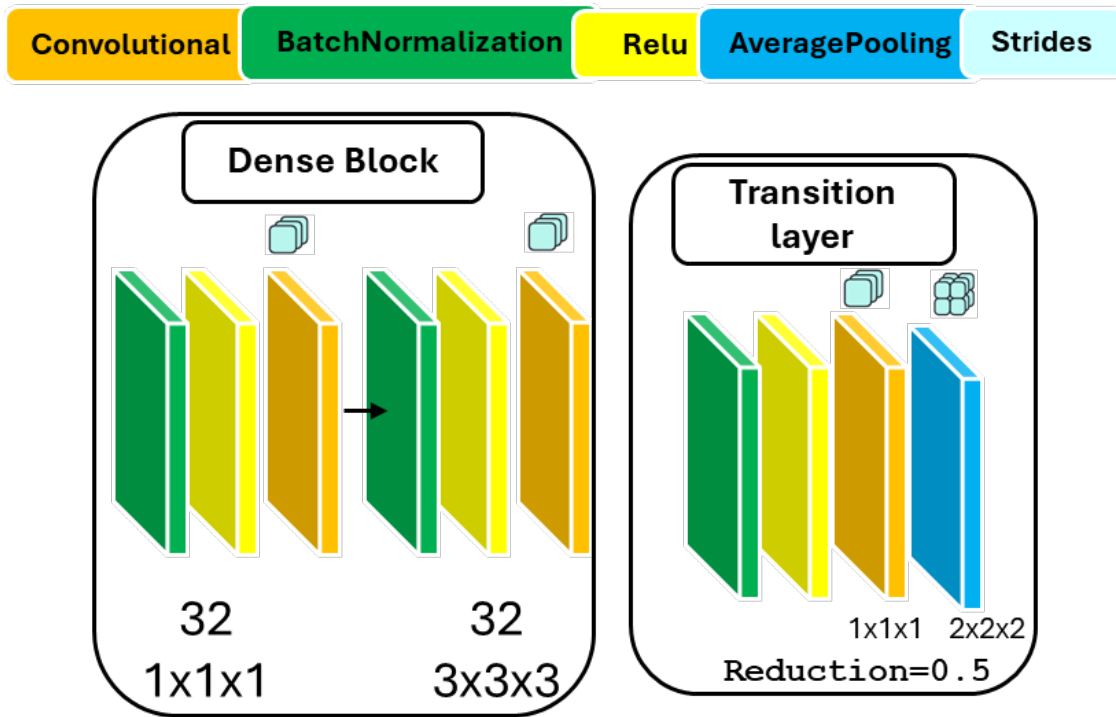


Figura 5.5: Bloque denso y capa de transición DenseNet3D (Fuente:Propia).

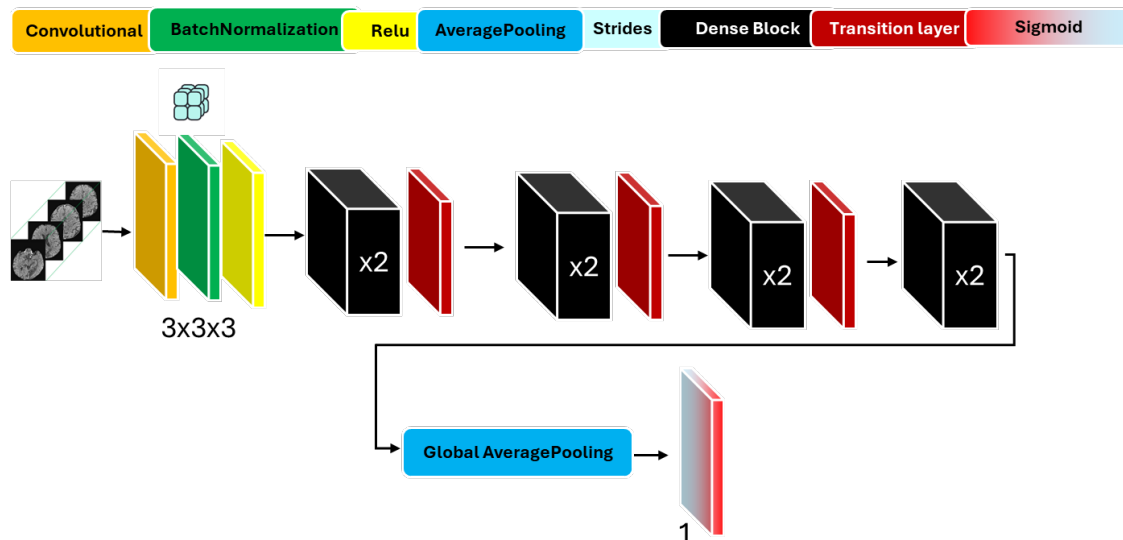


Figura 5.6: Diagrama de DenseNet3D, con tasa crecimiento de 32 y filtros iniciales de 32, con una tasa de abandono de 0.4 (Fuente:Propia).

- **Deep MultiScale 3D**: la arquitectura propuesta se basa en el artículo [50], en el cual se buscaba la clasificación de tumores cerebrales de glioma en gliomas de bajo grado (LGG) y gliomas de alto grado (HGG), debido a que la arquitectura tiene capas de up-sampling para segmentación, se eliminan estas capas y obtenemos cinco capas convolucionales y tres capas totalmente conectadas (FC), (aparte de las capas de agrupación máxima y normalización por lotes), con activación Relu y se utilizó regularización L2 y una tasa de abandono para disminuir el sobreajuste, en la figura 5.7, se ilustra la estructura del modelo.

A diferencia de las arquitecturas 2D-CNN, que no aprovechan por completo la información volumétrica presente en las imágenes de resonancia magnética (MRI) y se limitan a analizar cortes bidimensionales, utilizamos una capa convolucional 3D. Esta capa ofrece un mapa de características más detallado, capaz de explorar toda la información espacial volumétrica, lo que permite integrar tanto la información contextual local como la global de manera más completa [50].

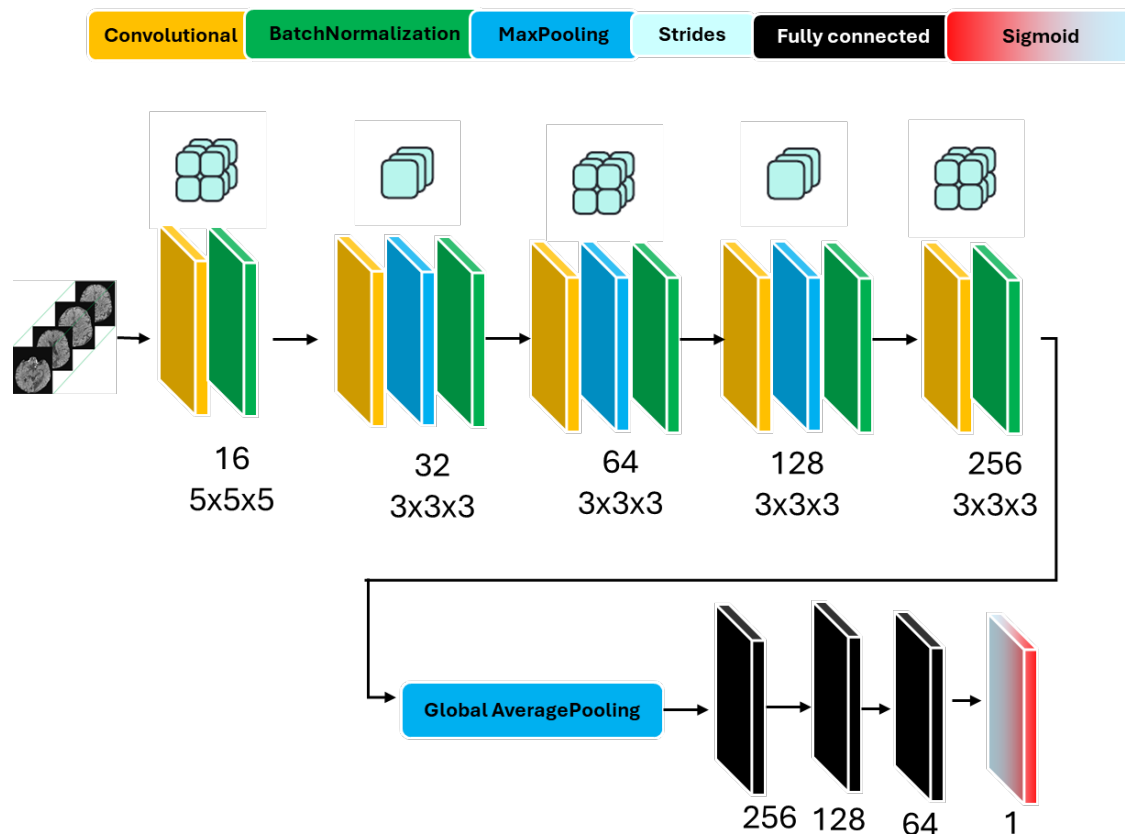


Figura 5.7: Diagrama Deep MultiScale 3D modificado (Fuente:Propia).

- **ICH 3D**: esta arquitectura se basa en el artículo [51], en el cual se usó para identificar hemorragia intracraneal (ICH), debido a la capacidad limitada de cómputo se modificó el número de filtros y neuronas, manteniendo la estructura del modelo, este está compuesto por cinco capas convolucionales y dos capas totalmente conectadas (aparte de las capas de agrupación máxima y normalización por lotes), con activación relu y se utilizó regularización L2 y una tasa de abandono para disminuir el sobreajuste, en la figura 5.8, se ilustra la estructura del modelo.

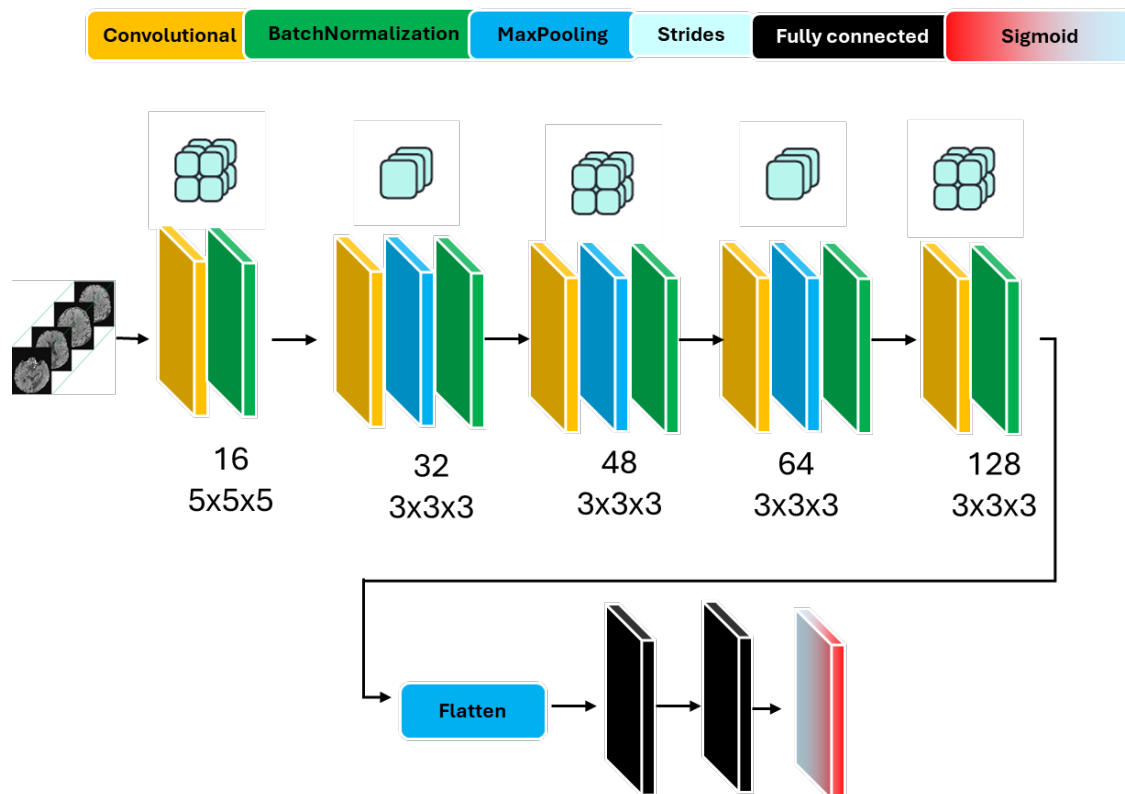


Figura 5.8: Diagrama de modelo ICH3D modificado (Fuente:Propia).

- **Máquinas de soporte vectorial (SVM)**: los vectores de entrada X se asignan de forma no lineal en un espacio de características de alta dimensión Z al elegir a priori, donde se construye una superficie de decisión lineal. La superficie de decisión con ciertas propiedades satisface la alta capacidad de generalización de la red. La superficie de decisión también se llama hiperplano, que se define como un límite de decisión lineal entre dos clases con margen máximo (es decir, Todo en un lado pertenece a una clase). Los vectores de soporte se definen como un conjunto de puntos o vectores en el margen del hiperplano de separación. Margen significa descubrir el punto más cercano al hiperplano y garantizar que esté tan lejos de la línea de separación [6].




Figura 5.9: Funcionamiento SVM (Fuente: [6]).

- **Kernel Linear:** este kernel calcula el producto escalar de los dos vectores y añade una constante opcional, lo que significa que no transforma el dataset a un espacio de mayor dimensionalidad [52].




Figura 5.10: Kernel lineal (Fuente: [7]).

- **Kernel RBF:** se usa comúnmente para asignar puntos de datos a un espacio de mayor dimensión donde se puede construir un límite de decisión lineal para separar clases [53].

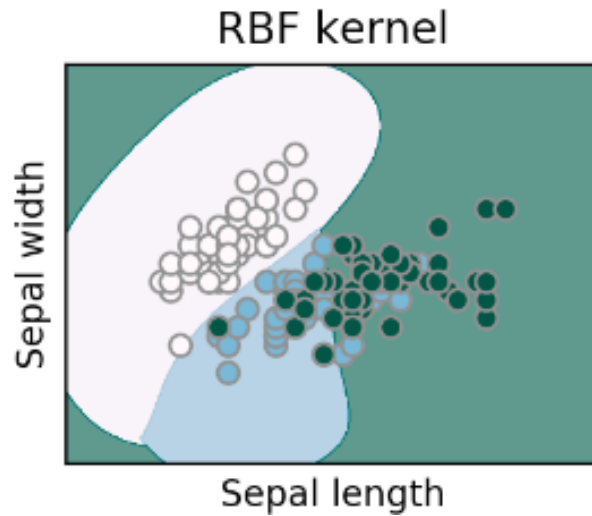


Figura 5.11: Kernel RBF (Fuente:[7]).

- **Kernel Polynomial:** para la clasificación, el modelo intenta maximizar el ancho del margen entre las clases usando un límite de clase polinómica. Para la regresión, el modelo optimiza una pérdida robusta, función que solo se ve afectada por residuos de modelos muy grandes y utiliza polinomios funciones de los predictores [54].




Figura 5.12: Kernel Polynomial (Fuente: [7]).

- **Algoritmo de Vecinos Más Cercanos:** el K-Nearest-Neighbors (KNN) es un algoritmo de clasificación no paramétrica, es decir, no hace ninguna suposición en el conjunto de datos elementales. Es conocido por su simplicidad de ejecución y bajo tiempo de cálculo, además de

su efectividad. Se proporciona un conjunto de datos de entrenamiento etiquetado donde los puntos de datos se clasifican en varias clases, de modo que se pueda predecir la clase de los datos no etiquetados [55].

En la clasificación, las diferentes características determinan la clase a la que pertenecen los datos no etiquetados. Se utiliza para clasificar los datos en función de los ejemplos de capacitación más cercanos o vecinos en una región determinada [56].

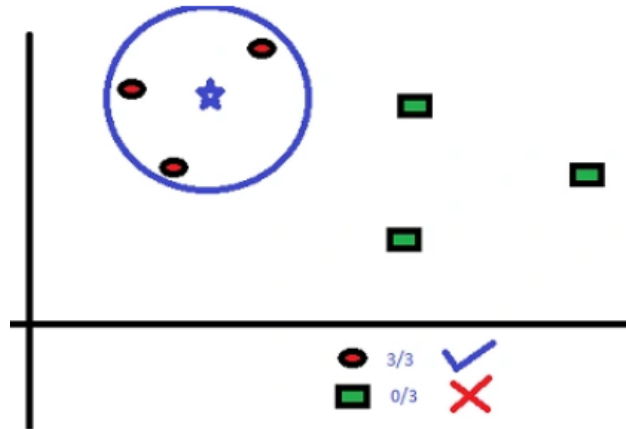


Figura 5.13: Funcionamiento KNN (Fuente:[8]).

Un valor K dado, nos permite establecer límites para cada clase. Estos límites de decisión segregan efectivamente, por ejemplo, clase A de Clase B. Del mismo modo, se examina el impacto del valor “K” en estos límites de clase. Lo siguiente ilustra los límites distintos que separan las dos clases, cada una correspondiente a diferentes valores de K [8].

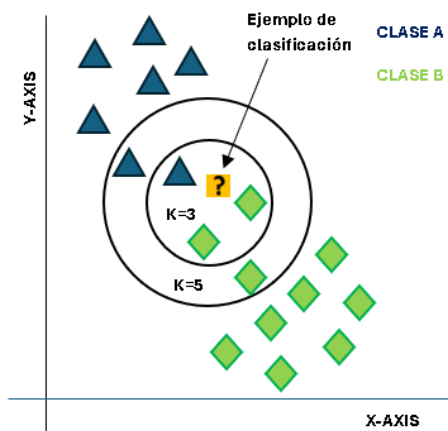


Figura 5.14: Ejemplo KNN con K=3 y K=5 vecinos (Fuente: Propia).

- **Perceptron Multicapa (MLP):** el Perceptrón Multicapa (MLP, por sus siglas en inglés) es una red neuronal artificial empleada en el aprendizaje supervisado dentro del campo del machine learning. Consiste en varias capas de neuronas conectadas entre sí, donde las salidas de una capa sirven como entradas para la siguiente. La capa inicial se denomina capa de entrada, la última se conoce como capa de salida, y las capas entre ellas son las capas ocultas [57]. El MLP es adecuado tanto para tareas de clasificación como de regresión, y se utiliza en situaciones donde la relación entre las variables de entrada y salida es no lineal. Su entrenamiento se realiza mediante el algoritmo de retropropagación (backpropagation), el cual ajusta los pesos de las conexiones de la red con el objetivo de reducir el error entre las salidas esperadas y las generadas por la red [58].
- **Extreme Gradient Boosting (XGBoost):** XGBoost es un algoritmo predictivo supervisado que se basa en el principio de boosting. La esencia del boosting es crear una serie de modelos de predicción “débiles” de manera secuencial, donde cada uno de estos modelos mejora los resultados del anterior, con el objetivo de formar un modelo “fuerte” que tenga un mejor poder predictivo y mayor estabilidad [59].

Para fortalecer estos modelos débiles, se utiliza un algoritmo de optimización, Gradient Descent. Durante el proceso de entrenamiento, los parámetros de cada modelo débil se ajustan de manera iterativa, buscando minimizar una función objetivo, que puede ser el error de clasificación, el área bajo la curva (AUC), la raíz del error cuadrático medio (RMSE), entre otras métricas [60].

Cada nuevo modelo es evaluado en comparación con el anterior. Si muestra mejores resultados, se toma como base para seguir mejorando. En caso de que el nuevo modelo rinda peor, se vuelve al mejor modelo previo y se modifica de manera distinta. El tamaño de los ajustes entre modelos es un hiperparámetro que el usuario debe definir [61].

Este proceso continúa hasta que la diferencia entre modelos consecutivos es mínima, lo que indica que se ha alcanzado el mejor modelo posible, o hasta que se llega al número máximo de iteraciones establecidas por el usuario.

XGBoost utiliza árboles de decisión como modelos débiles, los cuales pueden aplicarse tanto a tareas de clasificación como de regresión. Por ello, es útil revisar los fundamentos de los árboles de decisión para aprovechar al máximo este algoritmo [62].

- **Métricas de clasificación:** en la literatura se han utilizado diferentes métricas de evaluación para la clasificación de imágenes médicas, específicamente en segmentación de imágenes. Algunas de las métricas más utilizadas son:
- **Accuracy:** representa el porcentaje total de valores correctamente clasificados, tanto positivos como negativos. Se calcula como la suma de las predicciones verdaderas positivas y verdaderas negativas dividida por el número total de predicciones [63].

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (5.1)$$

Donde:

- **TP** (True Positives): Verdaderos positivos. Representa la cantidad de casos positivos que fueron correctamente identificados como positivos por el modelo.
 - **FP** (False Positives): Falsos positivos. Representa la cantidad de casos negativos que fueron incorrectamente identificados como positivos por el modelo.
 - **FN** (False Negatives): Falsos negativos. Representa la cantidad de casos positivos que fueron incorrectamente identificados como negativos por el modelo.
 - **TN** (True Negatives): Verdaderos negativos. Representa la cantidad de casos negativos que fueron correctamente identificados como negativos por el modelo.
- **Sensitivity (Recall o tasa de verdaderos positivos)**: esta métrica mide la proporción de casos positivos reales que se identificaron correctamente. Se calcula como el número de predicciones positivas verdaderas dividido por la suma de predicciones positivas verdaderas y negativas falsas [64].

$$\text{Sensitivity} = \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos negativos}} \quad (5.2)$$

- **Specificity (tasa de verdaderos negativos)**: esta métrica mide la proporción de casos negativos reales que se identificaron correctamente. Se calcula como el número de predicciones verdaderas negativas dividido por la suma de predicciones verdaderas negativas y falsas positivas [63].

$$\text{Specificity} = \frac{\text{Verdaderos negativos}}{\text{Verdaderos negativos} + \text{Falsos positivos}} \quad (5.3)$$

- **F1 Score**: esta métrica es la media armónica de precisión y recall. Proporciona un equilibrio entre precisión y recall, especialmente cuando las clases están desequilibradas [63]. Se calcula como:

$$\text{F1} = 2 \cdot \frac{\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (5.4)$$

- **AUC-ROC**: es el área bajo la curva ROC (Receiver Operating Characteristic). La curva ROC muestra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos a medida que se varía el umbral de clasificación. El AUC-ROC es una medida de la capacidad del modelo para distinguir entre clases positivas y negativas. Un valor de AUC-ROC cercano a 1 indica un buen rendimiento del modelo, mientras que un valor cercano a 0.5 indica un rendimiento aleatorio [63] [64].

A continuación se muestra un ejemplo utilizando un modelo de regresión logística en un pequeño conjunto de datos de prueba con la librería sklearn para mostrar el AUC.




Figura 5.15: Curva ROC (Salida del modelo de ejemplo) (Fuente: [9]).

- Matriz de confusión:** no se trata de una métrica única, sino de una tabla que se utiliza a menudo para describir el rendimiento de un modelo de clasificación. Muestra el número de predicciones verdaderas positivas, verdaderas negativas, falsas positivas y falsas negativas. A partir de esta matriz, se pueden derivar varias métricas como precisión, Sensitivity, Specificity y F1 score [63] [65]. En la figura 5.16, se puede observar un ejemplo de la matriz de confusión

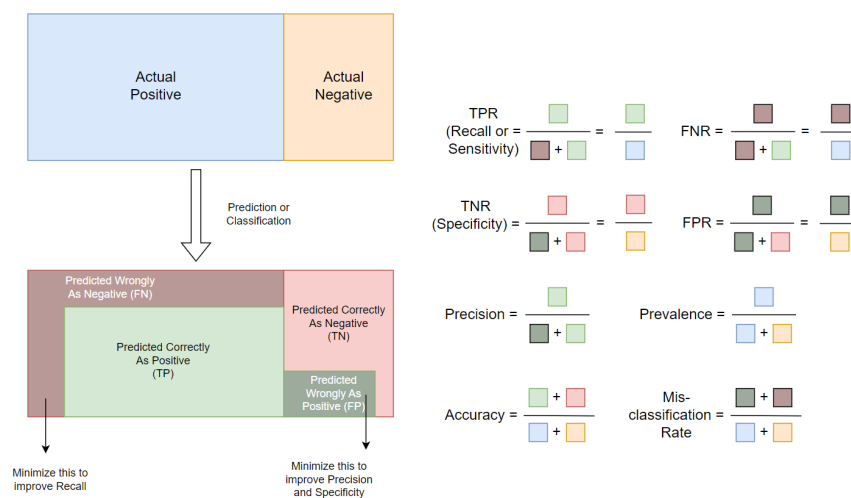


Figura 5.16: Matriz de confusión y métricas calculadas a partir de esta (Fuente: [10]).

5.3. Trabajos Relacionados

- **Machine Learning for Brain Stroke: A Review:** un estudio clasificó las técnicas de Machine Learning en cuatro categorías y revisó 39 investigaciones realizadas entre 2007 y 2019. Se encontró que las Máquinas de Soporte Vectorial (SVM) destacaron en 10 estudios sobre problemas de accidente cerebrovascular. Si bien se han realizado estudios sobre el diagnóstico, existe una escasez de investigaciones sobre el tratamiento del accidente cerebrovascular. Las imágenes de tomografía computarizada (CT) son ampliamente utilizadas en la investigación del accidente cerebrovascular. En resumen, las SVM y los Random Forests han demostrado ser eficaces en todas las categorías, resaltando la importancia del Machine Learning en la investigación del accidente cerebrovascular [66].
- **Prediction of Brain Stroke Severity Using Machine Learning:** este proyecto de grado emplea el aprendizaje automático para identificar, clasificar y predecir accidentes cerebrovasculares. Según la OMS, el 87% de los accidentes cerebrovasculares son de tipo isquémico. Se propone un algoritmo de Predicción de Accidentes Cerebrovasculares (SPN), basado en mejoras de Bosques Aleatorios, para superar las limitaciones de estudios previos en la predicción de factores de riesgo. El modelo alcanza una precisión del 96.97%, superando a otros enfoques previos [67].
- **Machine learning approach to detect the brain stroke disease:** este proyecto de grado destaca la importancia del cerebro como un órgano complejo y fundamental del cuerpo humano, protegido por el cráneo. Los accidentes cerebrovasculares, una de las principales causas de mortalidad, requieren una detección temprana para minimizar el daño cerebral. Este estudio propone un modelo basado en algoritmos de aprendizaje automático para predecir con alta precisión la ocurrencia de accidentes cerebrovasculares. Se implementan métodos avanzados de recopilación y procesamiento de datos en un conjunto de datos específico, evaluando el desempeño de clasificadores como Random Forest, Support Vector Machine y Decision Tree mediante métricas de evaluación. El modelo propuesto alcanza una precisión máxima del 95.30% con Random Forest, lo que confirma su eficacia en la predicción de accidentes cerebrovasculares [68].
- **Automatic detection of acute ischemic stroke using non-contrast computed tomography and two-stage deep learning model:** este estudio incluyó 238 casos provenientes de dos instituciones y utilizó imágenes de tomografía computarizada (CT) de cabeza para detectar hallazgos relacionados con el Accidente Isquémico Agudo (AIS). El conjunto de datos se dividió en entrenamiento (189 casos) y prueba (49 casos). Se desarrolló un modelo de detección de AIS en dos etapas, empleando los modelos You Only Look Once v3 (YOLOv3) y Visual Geometry Group 16 (VGG16). Un radiólogo evaluó las imágenes de CT tanto con como sin el modelo de detección. Para evaluar el modelo, se calcularon la sensibilidad y la tasa de falsos positivos. Los resultados del radiólogo, con y sin el modelo, se compararon mediante análisis estadístico. Este enfoque de detección puede ser relevante para futuras investigaciones sobre el AIS en trabajos de grado [69].

- **Automatic detection and vascular territory classification of hyperacute staged ischemic stroke on diffusion weighted image using convolutional neural networks:** este estudio tuvo como objetivo evaluar el desempeño de diversos modelos de redes neuronales convolucionales (CNN) en imágenes ponderadas por difusión (DWI) en etapas hiperagudas para la detección del accidente cerebrovascular isquémico (ACI) y su clasificación en infarto de circulación anterior (ACI), infarto de circulación posterior (PCI) y cortes de imagen normales. Se identificaron, descargaron y analizaron retrospectivamente 253 casos de DWI en etapa hiperaguda. Tras un proceso de exclusión, se seleccionaron 127 casos, conformando un conjunto de datos con 2119 cortes de imágenes, distribuidos en ACI (618 cortes), PCI (149 cortes) y normales (1352 cortes). Para el análisis, se emplearon dos modelos de CNN basados en aprendizaje por transferencia [70].
- **An automated early ischemic stroke detection system using CNN deep learning algorithm:** la ubicación del accidente cerebrovascular isquémico en una imagen de tomografía computarizada no es evidente, por lo que su diagnóstico depende de la evaluación médica a través de la observación de la imagen. El propósito de este artículo es desarrollar un sistema automatizado para la detección temprana del accidente cerebrovascular isquémico mediante un algoritmo de aprendizaje profundo basado en redes neuronales convolucionales (CNN). Tras ingresar la imagen de tomografía computarizada del cerebro, el sistema iniciará el pre-procesamiento de la imagen para eliminar las regiones irrelevantes que no corresponden a una posible área de accidente cerebrovascular [71].

Materiales y Métodos

6.1. Tipo de Estudio

El proyecto que se realizó, entra en el marco de un estudio de investigación aplicada, específicamente un estudio de inteligencia artificial, en este se busca identificar automáticamente el ACV isquémico en imágenes CT mediante técnicas de DL acopladas con algoritmos de aprendizaje automático para el soporte diagnóstico.

Para el desarrollo de este proyecto se realizó la revisión bibliográfica respecto a técnicas de DL existentes, después se gestionó y se procesó una base de datos de imágenes de CT que contienen casos de ACV isquémico y casos normales, pasando al entrenamiento de las arquitecturas modificadas y adaptadas para leer estudios volumétricos, los modelos tomados fueron ResNet-18 3D [4], ResNet-50 3D [5], DenseNet 3D [47], Deep MultiScale 3D [50] y una arquitectura CNN propuesta para la detección de ICH [51] posterior a esta implementación, se utilizaron los modelos como extractores de características y estas características se emplearon en diferentes clasificadores. Esto permitió medir el rendimiento tanto de la calidad de extracción de los modelos como el desempeño de los clasificadores con la información extraída. Para ellos se utilizaron métricas establecidas en la literatura, calificando así la efectividad del modelo con los clasificadores

Se debe tener en cuenta que, al utilizar bases de datos ya establecidas en el estudio, el análisis adopta una perspectiva retrospectiva. No se abordan implicaciones bioéticas, dado que no se lleva a cabo experimentación con pacientes.

6.2. Actividades

De acuerdo a los objetivos planteados, se ejecutaron las siguientes actividades.

OE1: Gestionar una base de datos de imágenes CT que contenga casos de ACV isquémico y casos normales para el entrenamiento de los algoritmos de aprendizaje.

▪ **Actividades:**

- T.1.1: Recopilar bases de datos de imágenes de tomografía computarizada que contenga casos que presenten ACV isquémico y casos normales.
- T.1.2: Estructurar y organizar la base de datos de manera adecuada, verificando que la clasificación de la información sea correcta y verídica.

De acuerdo a las actividades T.1.1 y T.1.2, se construyó la base de datos cumpliendo los

siguientes parámetros:

Protocolo para autorización de base de datos: La base de datos fue alimentada con los estudios proporcionados por la Fundación Valle del Lili, en conformidad con los parámetros y lineamientos establecidos por la institución. Para acceder a esta información, presenté un protocolo formal que detallaba el proyecto a realizar, el cual fue debidamente aprobado tras cumplir con los requisitos establecidos por la clínica. Gracias a este proceso, se me permitió obtener y utilizar los datos necesarios para el desarrollo de la investigación.

Para la evaluación del protocolo por parte del Comité de Ética en Investigación Biomédica de la Fundación Valle del Lili fue necesario que todos los investigadores de la propuesta contaran con el certificado de Buenas Prácticas Clínicas vigente, el cual fue enviado al Comité.

Se tuvo en cuenta las siguientes consideraciones éticas:

- La ejecución de este estudio se adhiere a la declaración de Helsinki de 2013, la resolución 8430 del 1993 y a las pautas CIOMS de 2016.
- El estudio se considera según la resolución 8430 de 1993; un estudio “sin riesgo”, ya que es un estudio retrospectivo y toda la información se obtendrá a partir de las historias clínicas, no se realizará ninguna intervención, ni modificación de las variables biológicas, fisiológicas, psicológicas o sociales de los individuos que participan en el estudio.
- Los investigadores se comprometen a cumplir con los principios y responsabilidades definidos en la Declaración de Singapur 2010 sobre integridad en la investigación.
- Los investigadores cuentan con un Acuerdo de Confidencialidad de Investigaciones Clínicas, estos documentos los encontraran en la sección de anexos (10).

Población de estudio: pacientes mayores de 18 años de cualquier sexo, atendidos en la Fundación Valle del Lili desde enero del 2018 hasta mayo del 2024 los cuales se dividieron en 50 %, casos de pacientes con ACV isquémico y 50 %, pacientes con TC cerebral simple sin otro diagnóstico del parénquima

Criterios de selección:

- **Inclusión:**
 1. Pacientes mayores de 18 años de cualquier sexo.
 2. Pacientes atendidos en la institución desde 2018 hasta 2024 con diagnóstico de ACV isquémico.
 3. Pacientes que se les haya tomado TC cerebral simple durante el mismo episodio de atención, sin otro diagnóstico del parénquima

4. Pacientes que presentan cambios en el parénquima cerebral acordes a la edad que tienen, estos son pérdida de volumen con leucoencefalopatía microangiopática.

○ **Exclusión:**

1. Paciente con cualquier otra condición neurológica que no sea acv isquémico
2. Pacientes que tengan artefactos por endurecimiento del haz del rayo, por movimiento, de tipo mecánicos entre otras y cualquier otro

la base obtenida consta de 1340 pacientes de los cuales 670 presentan ACV isquémico y 670 no presentan afectación, se realizó la descarga y anonimización de cada estudio referente a los pacientes por medio de algoritmos ejecutados en el programa Anaconda Navigator, respetando la confidencialidad estipulada por la FVL. Se organizaron los estudios en su respectiva carpeta pasándolos del formato Dicom a NRRD .

- T.1.3: Realizar un preprocesamiento de las imágenes CT buscando mejorar la calidad y eliminar posibles artefactos.

Preprocesamiento de los datos:

En la etapa de preprocesamiento de los estudios, se extrajo la parte del volumen correspondiente al cerebro, ya que era el área donde se buscaba detectar el ACV y varios estudios incluían las arterias carótidas y la región del cuello, que resultaba innecesaria y generaba un peso excesivo al momento de procesar cada volumen, en la figura 6.1, se ilustra como se llevo a cabo el proceso completo para procesar los estudios.

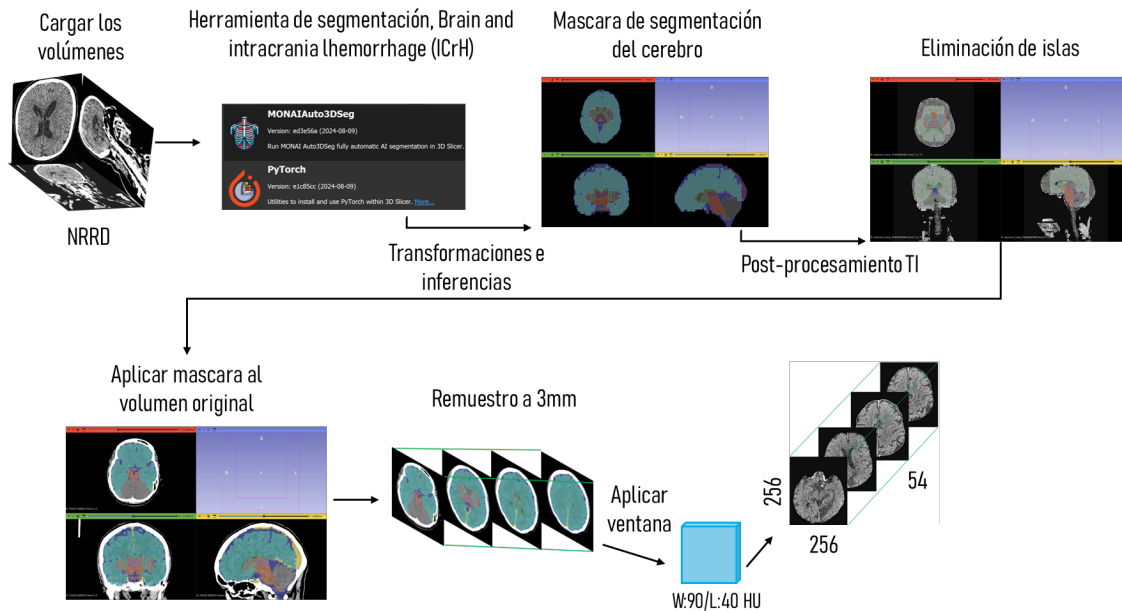


Figura 6.1: Diagrama de Preprocesamiento (Fuente: Propia).

Extracción de cerebro: el cerebro se extrajo a partir del software 3D Slicer [72], con

la extensión MONAIAuto3DSeg [73], la cual se usó como herramienta de segmentación 3D, empleando el modelo pre-entrenado para Brain and intracranial hemorrhage (ICrH) Segmentation, este modelo acompañado de un algoritmo, sigue el siguiente flujo:

1. Carga de modelo y volúmenes:

- Se cargó un modelo de segmentación en formato pt.
- Los volúmenes se pasaron a formato NRRD, se cargaron y prepararon para las inferencias.

2. Transformaciones:

- Se realizó normalización de intensidades, recorte de regiones de interés y reorientación a un sistema de coordenadas estándar(RAS).
- También se realizaron interpolaciones para ajustar diferentes resoluciones entre múltiples imágenes si es necesario.

3. Inferencia:

- Se realizó inferencias en las imágenes usando una ventana deslizante que maneja imágenes volumétricas.

4. Post-procesamiento:

- Obtenida la segmentación, se aplicaron transformaciones inversas para devolver la imagen a su espacio original y se eliminan las pequeñas regiones conectadas, denominadas islas.
- Se generaron máscaras que contienen solo la región cerebral y se guardaron en archivos NRRD.

5. Extracción y aplicación de la máscara:

- Se aplicó la máscara segmentada al volumen original para extraer únicamente el cerebro y se guardó el resultado en un nuevo archivo.

Se realizó un remuestreo de los volúmenes para dejarlos con un espaciado de 3mm con `itk.sitkLinear`, que es un método de interpolación lineal, se redimensionó cada corte a 256x256 con interpolación bilineal, se ajustó el número de cortes a 54, tomando como referencia el mayor número de cortes que se presentaba en los volúmenes, por ende se realizó padding para que los volúmenes que no tienen ese tamaño cumplieran con el estándar establecido, por último se aplicó una ventana de ACV la cual se estableció en $W(\text{ancho de la ventana}):90/L(\text{nivel de la ventana}):40$ HU y después se realizó la normalización.

- T.1.4: Dividir la base de datos en conjuntos de entrenamiento y validación, logrando una distribución equilibrada de casos de ACV isquémico y casos normales en cada conjunto.

Se separó el 70 % de las imágenes para el entrenamiento y el 30 % para la validación.

- T.1.5: Realizar una exploración y análisis de los datos para comprender las características y variaciones presentes en las imágenes CT.

- **Materiales**

- Base de datos
- Computador 1
- Anaconda Navigator, spyder

OE2: Implementar técnicas de aprendizaje profundo basada en redes neuronales convolucionales (CNN) que permitan identificar ACV isquémico en imágenes CT.

- **Actividades:**

- T.2.1: Investigar diferentes arquitecturas de redes neuronales convolucionales (CNN) adecuadas para la detección de ACV isquémico en imágenes CT.
- T.2.2: Implementar las arquitecturas de CNN utilizando librerías de DL, como Keras o PyTorch.
- T.2.3: Realizar el entrenamiento de las CNN, haciendo ajustes de hiperparámetros (Learning rate, épocas y funciones de activación).
- T.2.4: Utilizar los modelos como extractores de características.
De acuerdo a las actividades T.2.1, T.2.2, T.2.3 y T.2.4 se implementaron las siguientes 5 arquitecturas:
 - ResNet-18 3D [4]
 - ResNet-50 3D [5]
 - DenseNet 3D [47]
 - Deep MultiScale 3D [50]
 - ICH 3D [51]

-Se utilizó una base de datos cargada con 1340 volúmenes en cada modelo, ajustando los hiper-parámetros de acuerdo la carga computacional y rendimiento de los modelos. Se define la función de pérdida, entropía cruzada binaria y accuracy para evaluar el rendimiento del modelo en fase de entrenamiento y validación, se mantuvo la mezcla de datos durante el entrenamiento para aleatorizar el orden de las muestras en cada época, buscando mejorar la generalización del modelo al garantizar que no aprenda ningún patrón basado en el orden de los datos de entrenamiento y el tamaño de lote ajustó a 16.

-Se ajustó los hiperparámetros con **BayesianOptimization Tuner** [74], donde todos los modelos se corrieron en 5 entrenamientos de 20 épocas variando hiperparámetros.

-El mejor entrenamiento de cada modelo se utilizó como extractor de características y se corrió nuevamente a **50** épocas, con optimizador Adam y la función de pérdida de entropía cruzada binaria, clasificando a partir de la capa final del modelo, que produce una única salida con la función de activación sigmoide que transforma el valor de salida entre 0 y 1. Se utilizó `tf.keras.callbacks.ReduceLROnPlateau` para reducir dinámicamente la tasa de aprendizaje si el accuracy en validación se estancaba. Esta función monitorea “Val_accuracy” y reduce la tasa de aprendizaje en un factor de 0,2 cuando no se observa ninguna mejora durante 10 épocas, con un umbral mínimo de tasa de aprendizaje de 0.00001. Esto se hizo para evitar que el modelo se quede estancado en mínimos locales y permitir la convergencia.

- T.2.4: Utilizar las características extraídas en diferentes clasificadores buscando el mejor desempeño y capacidad de generalización en cada uno.
-Los clasificadores utilizados fueron SVM y kernel’s lineal, RBF, polinomial utilizando Grid Search, KNN evaluado con 3 y 5 vecinos, MLP y XGBoost, cada clasificador se probó en 10 iteraciones por modelo con una distribución aleatoria de los datos.

Se usaron con las siguientes especificaciones:

SVM con kernels RBF, polinomial: se definieron los parámetros a buscar en grid-search, para RBF, se define C: [0.1, 1, 10, 100] y gamma: [100, 10, 1, 0.1, 0.01, 0.001]. Para POLY, se define C: [0.1, 1, 10, 100], gamma: [100, 10, 1, 0.1, 0.01, 0.001] y degree: [2, 3, 4]. Donde ‘C’ funciona como un parámetro de regularización y “Gamma” controla la influencia de un solo punto de datos en el modelo y “Degree” se define como el grado del polinomio.

KNN: el clasificador usa distancia euclidiana.

MLP: este modelo de clasificación contiene dos capas ocultas(128 y 64 neuronas), usando una función de activación ReLU y el optimizador Adam. El modelo entrenará durante un máximo de 500 iteraciones o menos si converge mas rápido.

XGBoost: el clasificador usa el logaritmo de la pérdida (Log loss) como métrica de evaluación durante el entrenamiento, está configurado con 100 árboles de decisión y una tasa de aprendizaje del 30% (`learning_rate=0.3`). Los árboles tienen una profundidad máxima de 6 (`max_depth=6`), lo que controla su complejidad, mientras que se utiliza el 100% de las muestras para cada árbol (`subsample=1`) y todas las características disponibles (`colsample_bytree=1`). El modelo está orientado a clasificación binaria con regresión logística (`objective=“binary:logistic”`) y usa árboles de decisión como base (`booster=“gbtree”`). Además, se aplica regularización L2 estándar (`lambda=1`) para evitar el sobreajuste.

- **Materiales**

- Base de datos
- Computador 1 y 2
- Anaconda Navigator, spyder

OE3: Evaluar el rendimiento de las técnicas de DL empleando métricas de clasificación establecidas en la literatura de modo que se establezca el mejor modelo.

- **Actividades:**

- T.3.1: Evaluar el rendimiento de la CNN utilizando el conjunto de validación, y obtener las características generadas por el modelo antes de la clasificación.
- T.3.2: Comparar los resultados obtenidos por las distintas arquitecturas de CNN implementadas y los diferentes clasificadores de modo que se pueda establecer la eficacia de las técnicas de DL implementadas.
- T.3.3: Realizar análisis de errores y casos difíciles para identificar posibles mejoras en el modelo.
- T.3.4: Llevar a cabo estrategias de aumento de datos, con el fin de evitar el sobreentrenamiento(overfitting).
- T.3.5: Documentar y reportar los resultados obtenidos en un informe final de trabajo de grado, donde se discutan los modelos y su rendimiento en la detección de ACV isquémico en imágenes CT.

- **Materiales**

- Base de datos
- Computador 1 y 2
- Anaconda Navigator, spyder

6.2.1. Especificaciones de modelos

- **ResNet-18 3D:**

Para la evaluación de esta arquitectura, se utilizó el modelo de referencia que se muestra en la figura 5.3 y se adaptó utilizando capas convolucionales tridimensionales lo que permitió procesar datos volumétricos, extrayendo características espaciales en los diferentes planos anatómicos. Los bloques residuales son un elemento clave de la arquitectura ya que no permitieron la pérdida de información significativa entre capas, mejorando así la capacidad de la red para entrenar de manera eficiente.

Cada bloque residual, estuvo compuesto por dos capas convolucionales con Batch Normalization y la función de activación ReLU. Las salidas de estas capas convolucionales fueron

sumadas a la entrada original del bloque, para facilitar que la red mantuviera información de las capas profundas; de tal manera que en caso de que el número de filtros de la entrada no coincidiera con el de la salida, la entrada residual se ajustaría mediante una convolución de un kernel de tamaño 1x1 para igualar las dimensiones.

Etapas del modelo: se realizaron 4 capas donde la red comenzó con una convolución inicial de 64 filtros y un kernel de 7x7, seguida por una capa de Batch Normalization por lotes y una función de activación ReLU, continua a una capa de Max Pooling.

- **Primera capa:** consistió en dos bloques residuales con 64 filtros.
- **Segunda capa:** comprendió de dos bloques residuales con 128 filtros.
- **Tercera capa:** incluyó dos bloques residuales con 256 filtros.
- **Cuarta capa:** estuvo conformada por dos bloques residuales con 512 filtros.

Entre cada capa, se implementaron capas de Max Pooling para reducir las dimensiones del espacio de características.

Finalmente, se implementó una capa de *GlobalAveragePooling3D* para comprimir y obtener un vector de características global. Seguidamente, se utilizó una capa densa de 256 neuronas con un Dropout del 30% (0.3) para evitar el sobreajuste. Finalmente, la capa de salida consistió en una neurona con activación sigmoide, para dar respuesta a un problema de clasificación binaria.

El modelo fue compilado con el optimizador *Adam*, con una tasa de aprendizaje de 0.001 y una tasa de regularización L2 de 5.558632401072783e-05.

■ **ResNet-50 3D:**

El modelo usado como extractor de características fue compilado con una tasa de regularización L2 de 0.0006872780859788134, una tasa de aprendizaje de 0.001, tasa de dropout de 0.4 y una capa densa de 192 neuronas, sus resultados fueron.

■ **DenseNet 3D:**

El modelo usado como extractor de características fue compilado con una tasa de aprendizaje de 0.001, una tasa de dropout de 0.4 antes de la capa de salida y el tamaño de lote se dejó en 8 por la capacidad limitada de cómputo. El modelo está ilustrado en la figura 5.6.

■ **DeepMultiScale 3D:**

El modelo usado como extractor de características fue compilado con una tasa de regularización L2 de 0.003705560515312488, una tasa de aprendizaje de 0.0007243411260176605, una tasa de dropout en la capa 2(0.4), en la capa 3(0.2) y en la primera capa densa (0.2). El modelo está ilustrado en la figura 5.7.

■ **ICH 3D:**

El modelo usado como extractor de características fue compilado con una tasa de regularización

L2 de 0.0001, una tasa de aprendizaje de 0.001, una tasa de dropout en la capa 2(0.3), en la capa 3(0.3) y en la primera capa densa (0.5). El modelo está ilustrado en la figura 5.8.

6.3. Recursos

6.3.1. Técnicos

- **Base de datos:**
Volúmenes de tomografía computarizada de cerebro de pacientes con ACV y sin ACV, 1340 volúmenes, de tamaño 256x256x54, en formato NRRD.
- **Material bibliográfico:**
 - Artículos, repositorios, revistas y libros digitales
- **Programas:**
 - Anaconda Navigator, spyder.
 - Los algoritmos empleados los pueden encontrar en el siguiente link: <https://github.com/sebasecg/C-digos-Trabajo-de-grado/blob/main/Anexos%20c%C3%B3digos.txt>
- **Computador 1:**
 - Sistema operativo:** Windows 11 Pro 64 bits
 - Fabricante del sistema:** Dell inc.
 - Modelo del sistema:** Precision 3660
 - Procesador:** 13th Gen Intel(R) Core(TM) i7-13700k(24 CPUs), 3.4GHz
 - Memoria:** 32768MB RAM
 - Fabricante memoria gráfica:** NVIDIA
 - Memoria gráfica:** NVIDIA RTX A4000
 - Memoria total aproximada:** 32397MB
 - Memoria de pantalla (VRAM):** 16169MB
 - Memoria compartida:** 16228MB
- **Computador 2:**
 - Sistema operativo:** Windows 11 Pro 64 bits
 - Fabricante del sistema:** Dell inc.
 - Modelo del sistema:** Precision 3650 Tower
 - Procesador:** 11th Gen Intel(R) Core(TM) i7-11700k(16 CPUs), 2.5GHz
 - Memoria:** 32768MB RAM
 - Fabricante memoria gráfica:** NVIDIA
 - Memoria gráfica:** NVIDIA Geforce RTX 3060
 - Memoria total aproximada:** 28359MB
 - Memoria de pantalla (VRAM):** 12115MB
 - Memoria compartida:** 16244MB

Resultados y Discusión

7.1. Resultados experimentales

En esta sección se presentan los resultados que responden a los objetivos 2 y 3 del proyecto. El objetivo 2 busca implementar técnicas de aprendizaje profundo basada en redes neuronales convolucionales(CNN) que permitan identificar ACV isquémico en imágenes CT, pasando al objetivo 3, este busca evaluar el rendimiento de las técnicas de DL empleando métricas de clasificación establecidas en la literatura de modo que se establezca el mejor modelo.

7.1.1. ResNet-18 3D

1. **Modelo ResNet-18 3D, implementado como extractor de características, sus resultados fueron:**

Métrica	Resultado
Accuracy (Época: 47/50)	0.8025
F1-Score	0.8132
Sensitivity	0.8309
Specificity	0.7744
AUC-ROC	0.8648

Cuadro 7.1: Resultados del entrenamiento del modelo Resnet18-3D clasificando a partir de la capa final con la función de activación sigmoide.




Figura 7.1: Curva de loss y accuracy de ResNet-18 3D (Fuente: Propia).

En el cuadro 7.1, podemos ver que el modelo identifica correctamente casos positivos (ACV), esta medida es la Sensitivity, la cual tiene un valor 83.09 %, por otro lado, la Specificity que representa los casos normales tiene un valor de 77.44 %, mostrando que el desempeño identificando casos normales es menos robusto que al identificar ACV, lo que genera un 22.56 % de falsos positivos. En la gráfica de accuracy de la figura 7.1, podemos ver un sobreajuste a partir de época 30 limitando el aprendizaje de nuestro modelo.

2. Modelo evaluado con los clasificadores

a) SUPPORT VECTOR MACHINE

1) LINEAR

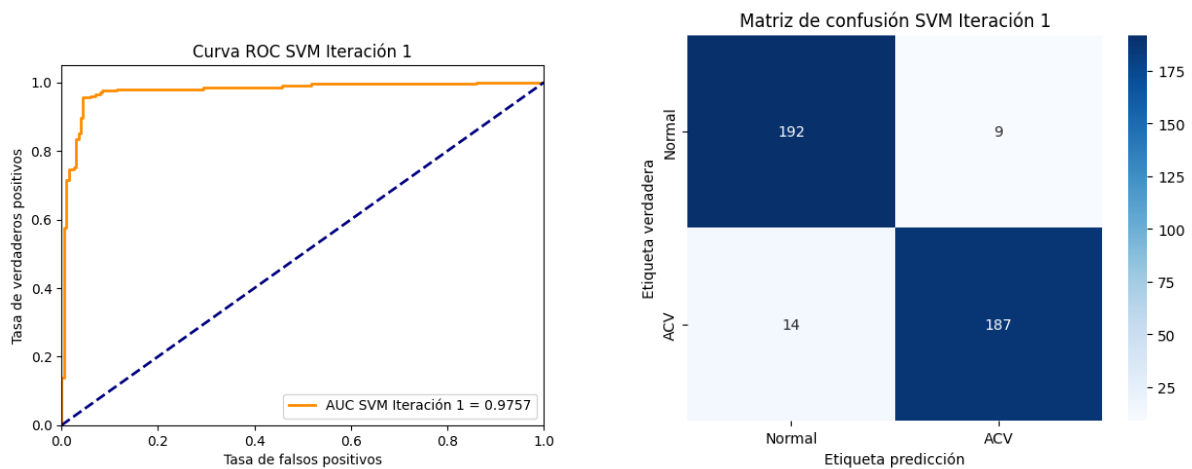


Figura 7.2: Curva AUC-ROC y matriz de confusión de SVM lineal+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9428	1

Cuadro 7.2: Mejor accuracy de svm con kernel lineal+ResNet-18 3D

2) RBF




Figura 7.3: Curva AUC-ROC y matriz de confusión de SVM RBF+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9552	3

Cuadro 7.3: Mejor accuracy con los hiperparámetros $C = 0.1$ y $\text{Gamma} = 0.01$ de SVM RBF+ResNet-18 3D

3) POLYNOMIAL




Figura 7.4: Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9552	8

Cuadro 7.4: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$, $\text{Degree} = 2$ de SVM POLYNOMIAL+ResNet-18 3D

b) K-NEAREST NEIGHBORS

1) 3 VECINOS

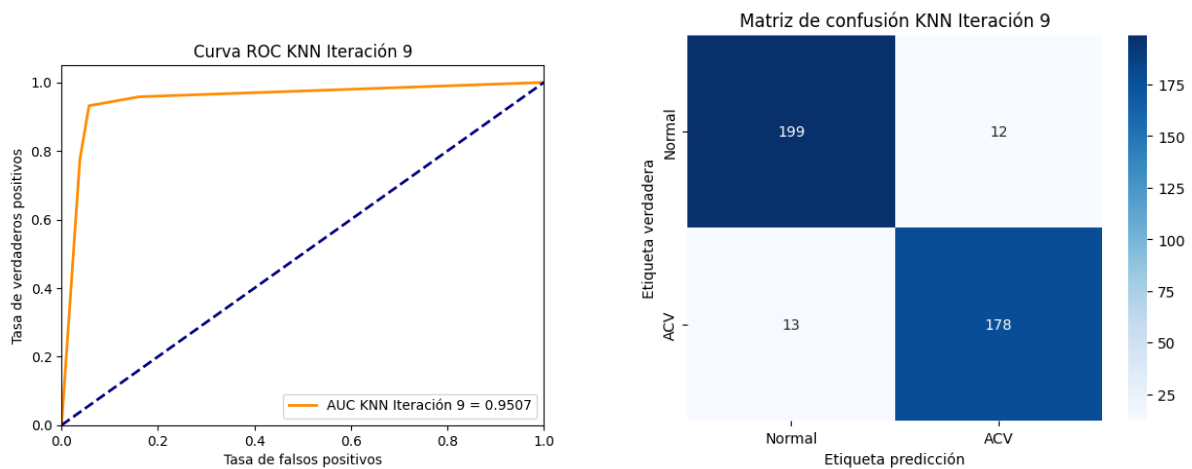


Figura 7.5: Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9378	9

Cuadro 7.5: Mejor accuracy de KNN 3 vecinos+ResNet-18 3D

2) 5 VECINOS




Figura 7.6: Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9502	4

Cuadro 7.6: Mejor accuracy de KNN 5 vecinos+ResNet-18 3D

c) MULTILAYER PERCEPTRON

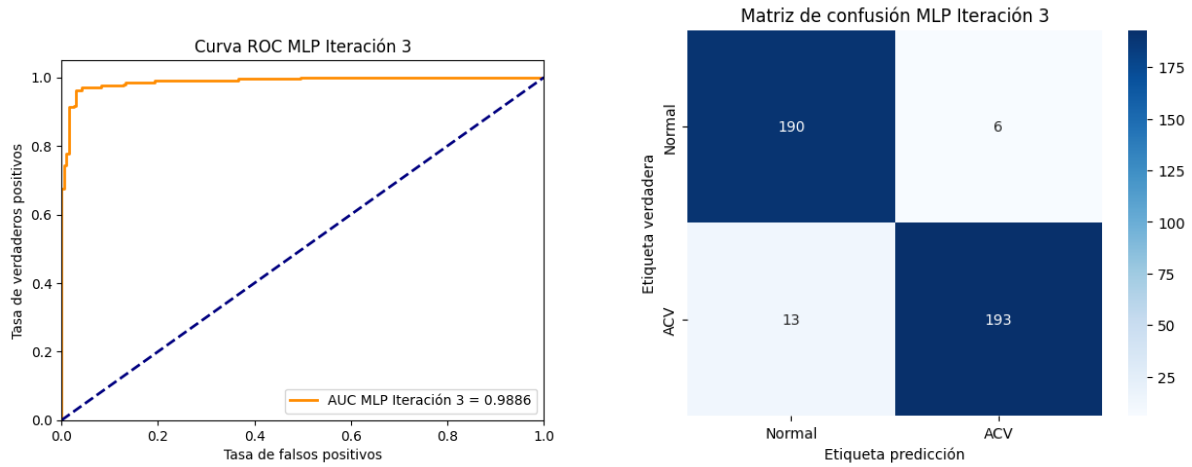


Figura 7.7: Curva AUC-ROC y matriz de confusión MLP+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9527	3

Cuadro 7.7: Mejor accuracy de MLP+ResNet-18 3D, alcanzado en 30 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.

d) XGBOOST




Figura 7.8: Curva AUC-ROC y matriz de confusión de XGBoost+ResNet-18 3D

Mejor Accuracy	No. Iteración
0.9701	10

Cuadro 7.8: Mejor accuracy de XGBoost+ResNet-18 3D

3. Cuadro métricas evaluadas para cada clasificador

	Accuracy	Sensitivity	Specificity	F1-Score	AUC-ROC
SVM Lineal	0.9361±0.0056	0.9406±0.0076	0.9314±0.0141	0.9367±0.0047	0.9757±0.0030
SVM RBF	0.9363±0.0093	0.9505±0.0130	0.9225±0.0104	0.9367±0.0097	0.9680±0.0094
SVM Polinomial	0.9415±0.0100	0.9551±0.0129	0.9280±0.0196	0.9426±0.0106	0.9778±0.0070
KNN 3	0.9231±0.0134	0.9183±0.0180	0.9281±0.0126	0.9224±0.0138	0.9466±0.0097
KNN 5	0.9266±0.0097	0.9282±0.0222	0.9246±0.0164	0.9274±0.0098	0.9565±0.0063
MLP	0.9366±0.0101	0.9524±0.0139	0.9211±0.0237	0.9371±0.0096	0.9743±0.0071
XGBoost	0.9331±0.0154	0.9418±0.0208	0.9246±0.0194	0.9335±0.0152	0.9705±0.0102

Cuadro 7.9: Promedios y desviaciones estándar de las métricas de ResNet-18 3D

Discusión ResNet-18 3D De acuerdo a los resultados presentados en el cuadro 7.9 el SVM polinomial destaca con el mayor Accuracy (94.15 %), Sensitivity (95.51) y F1-score (94.26 %), mostrando su efectividad para identificar clases positivas y negativas (ACV y no ACV), su alto AUC-ROC (97.78 %) respalda este comportamiento, evidenciando la capacidad de discriminar entre las dos clases. Los clasificadores SVM RBF y MLP presentan una Sensitivity similar con 95.05 % y 95.24 %, que se acerca al SVM polinomial, pero tiene una Specificity ligeramente menor que sugiere mas dificultades para identificar correctamente los casos normales. El clasificador SVM Lineal con AUC-ROC(97.57 %), muestre un buen equilibrio entre Sensitivity y Specificity, por otro lado MLP y XGBoost con AUC-ROC de 97.57 %, 97.43 %, 97.05 %, mantienen un buen rendimiento pero presentan una menor Specificity en comparación con la Sensitivity. En el cuadro 7.8 evidenciamos el mejor accuracy alcanzado por el modelo ResNet-18 3D, llegando al 97.01 %, el cual se generó con el clasificador XGBoost.

7.1.2. ResNet-50 3D

1. Modelo ResNet-50 3D, implementado como extractor de características, sus resultados fueron:

Métrica	Resultado
Accuracy (Época:36/50)	0.8085
F1-Score	0.8108
Sensitivity	0.7971
Specificity	0.8205
AUC-ROC	0.8689

Cuadro 7.10: Resultados del entrenamiento del modelo ResNet-50 3D clasificando a partir de la capa final con la función de activación sigmoide




Figura 7.9: Curva de loss y accuracy de ResNet-50 3D (Fuente: Propia).

En el cuadro 7.10, podemos ver que el modelo identifica tanto casos de ACV como normales, en forma similar, presentando 79.71 % en Sensitivity y 82.05 % en Specificity, pero hay una leve diferencia que indica el desempeño del modelo inclinado a identificar mejor casos normales, por otro lado, esta diferencia mínima se ve reflejado en el AUC.ROC con 86.89 %, mostrando un buen equilibrio entre las dos clases. En la gráfica de accuracy de la figura 7.9, podemos ver un sobreajuste a partir de época 37 limitando el aprendizaje de nuestro modelo.

2. Modelo evaluado con los clasificadores

a) SUPPORT VECTOR MACHINE

1) LINEAR

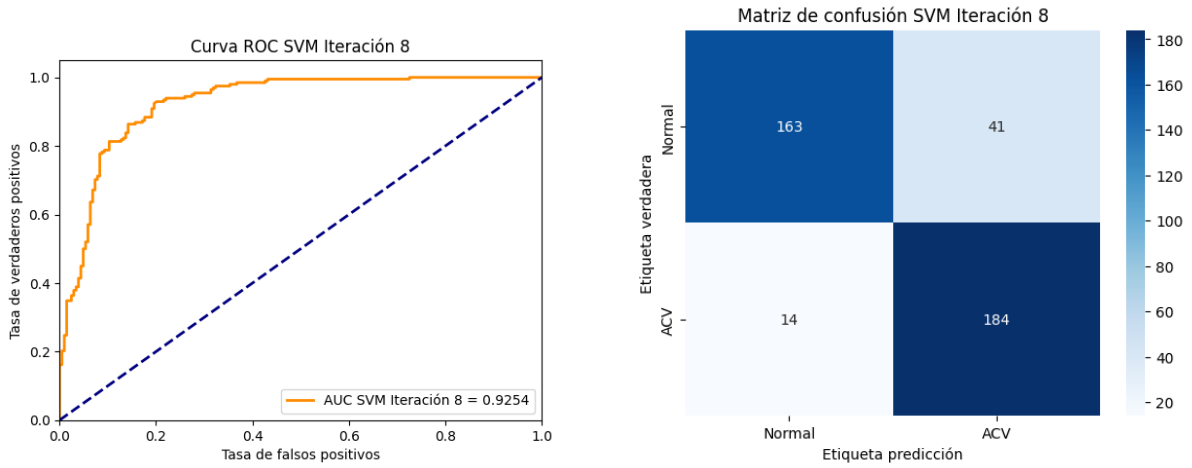


Figura 7.10: Curva AUC-ROC y matriz de confusión de SVM lineal+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8632	8

Cuadro 7.11: Mejor accuracy de svm con kernel lineal+ResNet-50 3D

2) RBF

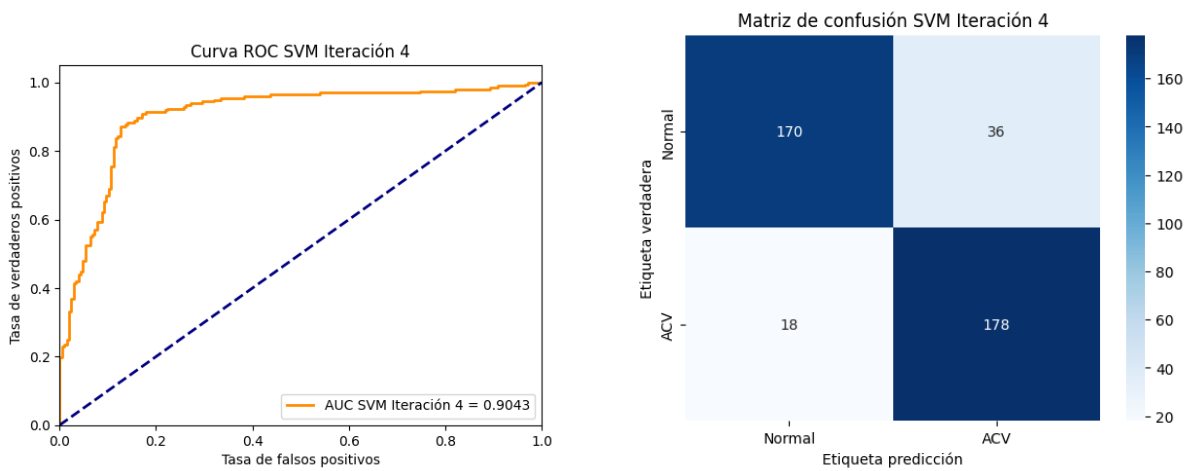


Figura 7.11: Curva AUC-ROC y matriz de confusión de SVM RBF+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8657	4

Cuadro 7.12: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$ de SVM RBF+ResNet-50 3D

3) POLYNOMIAL




Figura 7.12: Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8682	2

Cuadro 7.13: Mejor accuracy con los hiperparámetros $C = 0.1$, $\text{Gamma} = 0.001$, $\text{Degree} = 3$ de POLYNOMIAL+ResNet-50 3D

b) K-NEAREST NEIGHBORS

1) 3 VECINOS




Figura 7.13: Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8483	6

Cuadro 7.14: Mejor accuracy de KNN 3 vecinos+ResNet-50 3D

2) 5 VECINOS




Figura 7.14: Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8607	7

Cuadro 7.15: Mejor accuracy de KNN 5 vecinos+ResNet-50 3D

c) MULTILAYER PERCEPTRON




Figura 7.15: Curva AUC-ROC y matriz de confusión de MLP+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8557	7

Cuadro 7.16: Mejor accuracy de MLP+ResNet-50 3D, alcanzado en 60 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.

d) XGBOOST




Figura 7.16: Curva AUC-ROC y matriz de confusión de XGBoost+ResNet-50 3D

Mejor Accuracy	No. Iteración
0.8458	4

Cuadro 7.17: Mejor accuracy de XGBoost+ResNet-50 3D

3. Cuadro métricas evaluadas para cada clasificador

	Accuracy	Sensitivity	Specificity	F1-Score	AUC-ROC
SVM Lineal	0.8507±0.0100	0.8934±0.0259	0.8103±0.0229	0.8538±0.0111	0.9200±0.0071
SVM RBF	0.8475±0.0115	0.8880±0.0150	0.8070±0.0230	0.8527±0.0105	0.9014±0.0081
SVM Polinomial	0.8433±0.0170	0.9032±0.0311	0.7845±0.0268	0.8520±0.0166	0.9122±0.0145
KNN 3	0.8226±0.0139	0.8511±0.0279	0.7951±0.0145	0.8256±0.0163	0.8679±0.0129
KNN 5	0.8296±0.0150	0.8401±0.0239	0.8189±0.0238	0.8327±0.0175	0.8885±0.0134
MLP	0.8410±0.0081	0.8736±0.0227	0.8091±0.0225	0.8460±0.0095	0.9153±0.0040
XGBoost	0.8306±0.0115	0.8494±0.0171	0.8136±0.0240	0.8305±0.0121	0.9028±0.0088

Cuadro 7.18: Promedios y desviaciones estándar de las métricas de ResNet-50 3D

Discusión ResNet-50 3D Para el análisis del cuadro 7.18 del modelo ResNet-50 3D, el SVM Lineal mostró un buen equilibrio entre Sensitivity (89.34%) y specificity (81.03%), logrando una Accuracy de 85.07%, un F1-Score de 85.38%, y un AUC-ROC de 92.00%. Esto lo posiciona como una opción confiable para la clasificación de imágenes médicas. El SVM Polinomial, con una

Sensitivity de 90.32% y un F1-Score de 85.20%, destacó en la detección de casos positivos, aunque su Specificity fue más baja (78.45%). El SVM RBF tuvo un desempeño equilibrado, con una Accuracy de 84.75%, un F1-Score de 85.27%, pero con menor Specificity en comparación con el SVM Lineal. El MLP mostró un rendimiento competitivo, con una Accuracy de 84.10%, F1-Score de 84.60%, y un AUC-ROC de 91.53%. Los modelos KNN (KNN 3 y KNN 5) mostraron un rendimiento inferior, con F1-Scores de 82.56% y 83.27%, respectivamente. Finalmente, el XGBoost obtuvo una Accuracy de 83.06%, un F1-Score de 83.05%, y un AUC-ROC de 90.28%. Siendo así, las variantes de SVM, especialmente el SVM Lineal, se destacaron en la clasificación tridimensional de imágenes, mostrando un buen balance entre las métricas clave. De acuerdo al cuadro 7.13 evidenciamos el mejor Accuracy alcanzado por el modelo ResNet-50 3D, llegando al 86.82%, el cual se genero con el clasificador SVM con kernel POLINOMIAL despues de realizar un gridsearch el cual arrojó los hiperparámetros $C = 0.1$, $\text{Gamma} = 0.001$, $\text{Degree} = 3$ que hicieron posible este resultado.

7.1.3. DenseNet 3D

1. Modelo DenseNet 3D, implementado como extractor de características, sus resultados fueron:

Métrica	Resultado
Accuracy (Época:25/50)	0.7836
F1-Score	0.7873
Sensitivity	0.7778
Specificity	0.7897
AUC-ROC	0.8600

Cuadro 7.19: Resultados del entrenamiento del modelo DenseNet 3D clasificando a partir de la capa final con la función de activación sigmoide




Figura 7.17: Curva de loss y accuracy DenseNet 3D (Fuente: Propia).

En el cuadro 7.19, podemos ver que el modelo identifica tanto casos de ACV como normales, en forma similar, presentando 77.78 % en Sensitivity y 78.97 % en Specificity, por otro lado, se ve reflejado el equilibrio entre estas dos métricas en el AUC.ROC con 86.00 %. En la gráfica de accuracy de la figura 7.17, podemos ver un sobreajuste leve a partir de época 30, pero la brecha entre el entrenamiento y la validación no se muestra mayor valor.

2. Modelo evaluado con los clasificadores

a) SUPPORT VECTOR MACHINE

1) LINEAR




Figura 7.18: Curva AUC-ROC y matriz de confusión de SVM lineal+DenseNet 3D

Mejor Accuracy	No. Iteración
0.8085	4

Cuadro 7.20: Mejor accuracy de svm con kernel lineal+DenseNet 3D

2) RBF




Figura 7.19: Curva AUC-ROC y matriz de confusión de SVM RBF+DenseNet 3D

Mejor Accuracy	No. Iteración
0.8085	3

Cuadro 7.21: Mejor accuracy con los hiperparámetros $C = 100$, $\text{Gamma} = 0.01$ de SVM RBF+DenseNet 3D

3) POLYNOMIAL




Figura 7.20: Curva AUC-ROC y matriz de confusión de SVM POLINOMIAL+DenseNet 3D

Mejor Accuracy	No. Iteración
0.8134	8

Cuadro 7.22: Mejor accuracy los hiperparámetros $C = 1$, $\text{Gamma} = 0.1$, $\text{Degree} = 3$ de SVM POLINOMIAL+DenseNet 3D

b) K-NEAREST NEIGHBORS

1) 3 VECINOS




Figura 7.21: Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+DenseNet 3D

Mejor Accuracy	No. Iteración
0.7562	3

Cuadro 7.23: Mejor accuracy de knn 3 vecinos+DenseNet 3D

2) 5 VECINOS




Figura 7.22: Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+DenseNet 3D

Mejor Accuracy	No. Iteración
0.7811	8

Cuadro 7.24: Mejor accuracy de knn 5 vecinos+DenseNet 3D

c) MULTILAYER PERCEPTRON




Figura 7.23: Curva AUC-ROC y matriz de confusión de MLP+DenseNet 3D

Mejor Accuracy	No. Iteración
0.7935	10

Cuadro 7.25: Mejor accuracy de MLP+DenseNet 3D, alcanzado en 72 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.

d) XGBOOST




Figura 7.24: Curva AUC-ROC y matriz de confusión de XGBoost+DenseNet 3D

Mejor Accuracy	No. Iteración
0.7836	9

Cuadro 7.26: Mejor accuracy de XGBoost+DenseNet 3D

3. Cuadro métricas evaluadas para cada clasificador

	Accuracy	Sensitivity	Specificity	F1-Score	AUC-ROC
SVM Lineal	0.7843±0.0114	0.7952±0.0210	0.7751±0.0328	0.7868±0.0121	0.8657±0.0134
SVM RBF	0.7871±0.0136	0.8000±0.0310	0.7747±0.0295	0.7912±0.0157	0.8586±0.0129
SVM Polinomial	0.7903±0.0146	0.8173±0.0247	0.7642±0.0245	0.7940±0.0140	0.8693±0.0157
KNN 3	0.7333±0.0150	0.7345±0.0181	0.7324±0.0254	0.7334±0.0139	0.7951±0.0164
KNN 5	0.7540±0.0170	0.7612±0.0391	0.7474±0.0210	0.7544±0.0222	0.8195±0.0150
MLP	0.7659±0.0182	0.7889±0.0646	0.7411±0.0570	0.7722±0.0252	0.8530±0.0102
XGBoost	0.7540±0.0197	0.7580±0.0367	0.7505±0.0187	0.7542±0.0231	0.8349±0.0133

Cuadro 7.27: Promedios y desviaciones estándar de las métricas de DenseNet 3D

Discusión DenseNet 3D En el cuadro 7.27 podemos ver que el modelo SVM Polinomial se destaca con un Accuracy del 79.03 %, lo que indica una capacidad superior para clasificar correctamente los casos en comparación con otros modelos. A su vez, muestra una Sensitivity del 81.73 %, lo que resalta la capacidad para identificar verdaderos positivos, un aspecto crítico en aplicaciones donde la detección temprana es fundamental. En cuanto a la Specificity, el SVM Lineal tiene un 77.51 %,

evidenciando su efectividad en la identificación de casos negativos. El F1-Score del SVM Polinomial, que es de 79.40 %, refleja un buen balance entre precisión y Sensitivity, lo cual es esencial para la evaluación general del rendimiento del modelo. Por otro lado, el modelo KNN 3 muestra el rendimiento más bajo, con un Accuracy del 73.33 % y una Sensitivity de 73.45 %, lo que sugiere que tiene una menor capacidad para detectar correctamente los casos positivos. Finalmente, el AUC-ROC más alto se observa en el SVM Polinomial con un valor de 86.93 %, indicando su robustez en la discriminación entre clases. Estos resultados proponen que los modelos SVM, particularmente el Polinomial, son los más adecuados para la tarea de clasificación en el contexto analizado, superando a otros enfoques como KNN y XGBoost en términos de efectividad general.

De acuerdo al cuadro 7.22 evidenciamos el mejor Accuracy alcanzado por el modelo DenseNet 3D, llegando al 81.34 %, el cual se generó con el clasificador SVM con kernel POLINOMIAL después de realizar un gridsearch el cual arrojó los hiperparámetros $C = 1$, $\text{Gamma} = 0.1$, $\text{Degree} = 3$ que hicieron posible este resultado.

7.1.4. DeepMultiScale 3D

1. Modelo DeepMultiScale 3D, implementado como extractor de características, sus resultados fueron:

Métrica	Resultado
Accuracy (Época:39/50)	0.7650
F1-Score	0.7912
Sensitivity	0.8696
Specificity	0.6513
AUC-ROC	0.8217

Cuadro 7.28: Resultados del entrenamiento del modelo DeepMultiScale 3D clasificando a partir de la capa final con la función de activación sigmoide




Figura 7.25: Curva de loss y accuracy de DeepMultiScale 3D (Fuente: Propia).

En el cuadro 7.28, podemos ver que el modelo identifica correctamente casos positivos (ACV), esta medida es la Sensitivity, la cual tiene un valor 86.96%, por otro lado, la Specificity que representa los casos normales, tiene un valor de 65.13%, mostrando que el desempeño identificando casos normales es en gran medida menos robusto que al identificar ACV, generando un 34.87% de falsos positivos. En la gráfica de accuracy de la figura 7.25, podemos ver un sobreajuste notorio a partir de época 24 estancando el aprendizaje de nuestro modelo.

2. Modelo evaluado con los clasificadores

a) SUPPORT VECTOR MACHINE

1) LINEAR




Figura 7.26: Curva AUC-ROC y matriz de confusión de SVM lineal+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9378	6

Cuadro 7.29: Mejor accuracy de svm con kernel lineal+DeepMultiScale 3D

2) RBF




Figura 7.27: Curva AUC-ROC y matriz de confusión de SVM RBF+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9453	9

Cuadro 7.30: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.01$ de SVM RBF+DeepMultiScale 3D

3) POLYNOMIAL




Figura 7.28: Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9453	1

Cuadro 7.31: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.1$, $\text{Degree} = 2$ de SVM POLYNOMIAL+DeepMultiScale 3D

b) K-NEAREST NEIGHBORS

1) 3 VECINOS




Figura 7.29: Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9378	4

Cuadro 7.32: Mejor accuracy de KNN 3 vecinos+Deep MultiScale-3D

2) 5 VECINOS




Figura 7.30: Curva AUC-ROC y matriz de confusión de KNN 5 vecinos+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9378	2

Cuadro 7.33: Mejor accuracy de KNN 5 vecinos+Deep MultiScale-3D

c) MULTILAYER PERCEPTRON




Figura 7.31: Curva AUC-ROC y matriz de confusión de MLP+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9328	2

Cuadro 7.34: Mejor accuracy de MLP+DeepMultiScale 3D, alcanzado en 166 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.

d) XGBOOST




Figura 7.32: Curva AUC-ROC y matriz de confusión de XGBoost+DeepMultiScale 3D

Mejor Accuracy	No. Iteración
0.9502	1

Cuadro 7.35: Mejor accuracy de XGBoost+DeepMultiScale 3D

3. Cuadro métricas evaluadas para cada clasificador

	Accuracy	Sensitivity	Specificity	F1-Score	AUC-ROC
SVM Lineal	0.9241±0.0083	0.9255±0.0167	0.9229±0.0150	0.9241±0.0072	0.9738±0.0053
SVM RBF	0.9261±0.0097	0.9420±0.0146	0.9102±0.0250	0.9260±0.0089	0.9716±0.0076
SVM Polinomial	0.9264±0.0102	0.9323±0.0221	0.9199±0.0254	0.9269±0.0098	0.9756±0.0056
KNN 3	0.9199±0.0127	0.9241±0.0195	0.9152±0.0162	0.9201±0.0137	0.9525±0.0100
KNN 5	0.9219±0.0109	0.9403±0.0164	0.9037±0.0261	0.9232±0.0096	0.9639±0.0076
MLP	0.9209±0.0076	0.9281±0.0193	0.9131±0.0199	0.9205±0.0084	0.9718±0.0059
XGBoost	0.9274±0.0161	0.9283±0.0161	0.9267±0.0280	0.9278±0.0156	0.9708±0.0076

Cuadro 7.36: Promedios y desviaciones estándar de las métricas de DeepMultiScale 3D

Discusión DeepMultiScale 3D En el cuadro 7.36 El modelo SVM Polinomial se destaca con un Accuracy del 92.64%, reflejando una notable capacidad para realizar clasificaciones correctas. Esta métrica representa la proporción de predicciones correctas entre el total de casos evaluados. Además, el SVM Polinomial exhibe una Sensitivity del 93.23%, que indica la capacidad del modelo para identificar correctamente los casos positivos. La Sensitivity es esencial en contextos donde es

crítico detectar la presencia de una condición, ya que se enfoca en la tasa de verdaderos positivos. Por otro lado, el SVM RBF muestra una Specificity del 91.02 %, lo que resalta su eficacia en la detección de negativos verdaderos, es decir, su habilidad para identificar correctamente los casos negativos. El F1-Score alcanzado por el SVM Polinomial, que se sitúa en 92.69 %, sugiere un balance adecuado entre precisión y Sensitivity. Aunque el modelo KNN 3 presenta un Accuracy del 91.99 %, su Sensitivity de 92.41 % lo posiciona como un contendiente sólido, aunque con un rendimiento un poco inferior al de los modelos SVM. Finalmente, el modelo SVM Polinomial también logra el mayor AUC-ROC con un valor de 97.56 %, lo que indica su alta capacidad para diferenciar entre las distintas clases. En conjunto, los resultados indican que los modelos SVM son los más efectivos para la clasificación en este contexto, superando a alternativas como KNN y XGBoost en términos de desempeño general. De acuerdo al cuadro 7.35 evidenciamos el mejor Accuracy alcanzado por el modelo DeepMultiScale 3D, llegando al 95.02 %, el cual se generó con el clasificador XGBoost.

7.1.5. ICH 3D

1. Modelo ICH 3D, implementado como extractor de características, sus resultados fueron:

Métrica	Resultado
Accuracy (Época:44/50)	0.7798
F1-Score	0.7991
Sensitivity	0.9034
Specificity	0.6205
AUC-ROC	0.7777

Cuadro 7.37: Resultados del entrenamiento del modelo ICH 3D clasificando a partir de la capa final con la función de activación sigmoide




Figura 7.33: Curva de loss y accuracy ICH 3D (Fuente: Propia)

En el cuadro 7.37, podemos ver que el modelo identifica correctamente casos positivos (ACV), esta medida es la Sensitivity, la cual tiene un valor 90.34 %, por otro lado, la Specificity que representa los casos normales, tiene un valor de 62.05 %, mostrando que el desempeño identificando casos normales es en gran medida menos robusto que al identificar ACV, generando un 37.95 % de falsos positivos. En la gráfica de accuracy de la figura 7.25, podemos ver un sobreajuste notorio a partir de época 35 estancando el aprendizaje de nuestro modelo.

2. Modelo evaluado con los clasificadores

a) SUPPORT VECTOR MACHINE

1) LINEAR




Figura 7.34: Curva AUC-ROC y matriz de confusión de SVM lineal+ICH 3D

Mejor Accuracy	No. Iteración
0.9005	4

Cuadro 7.38: Mejor accuracy de svm con kernel lineal+ICH-3D

2) RBF




Figura 7.35: Curva AUC-ROC y matriz de confusión de SVM RBF+ICH 3D

Mejor Accuracy	No. Iteración
0.9403	8

Cuadro 7.39: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.001$ de SVM RBF+ICH 3D

3) POLYNOMIAL




Figura 7.36: Curva AUC-ROC y matriz de confusión de SVM POLYNOMIAL+ICH 3D

Mejor Accuracy	No. Iteración
0.9229	7

Cuadro 7.40: Mejor accuracy con los hiperparámetros $C = 1$, $\text{Gamma} = 0.001$, $\text{Degree} = 2$ de SVM POLYNOMIAL+ICH 3D

b) K-NEAREST NEIGHBORS

1) 3 VECINOS




Figura 7.37: Curva AUC-ROC y matriz de confusión de KNN 3 vecinos+ICH 3D

Mejor Accuracy	No. Iteración
0.8507	4

Cuadro 7.41: Mejor accuracy de KNN 3 vecinos+ICH-3D

2) 5 VECINOS




Figura 7.38: Curva AUC-ROC y matriz de confusión de KNN5+ICH 3D

Mejor Accuracy	No. Iteración
0.8705	5

Cuadro 7.42: Mejor accuracy de KNN 5 vecinos+ICH-3D

c) MULTILAYER PERCEPTRON




Figura 7.39: Curva AUC-ROC y matriz de confusión de MLP+ICH 3D

Mejor Accuracy	No. Iteración
0.9154	2

Cuadro 7.43: Mejor accuracy de MLP+ICH 3D, alcanzado en 44 pasos que el optimizador realiza para ajustar los pesos del modelo y minimizar la función de pérdida.

d) XGBOOST




Figura 7.40: Curva AUC-ROC y matriz de confusión de XGBoost+ICH 3D

Mejor Accuracy	No. Iteración
0.9179	9

Cuadro 7.44: Mejor accuracy de XGBoost+ICH 3D

3. Cuadro métricas evaluadas para cada clasificador

	Accuracy	Sensitivity	Specificity	F1-Score	AUC-ROC
SVM Lineal	0.8841±0.0141	0.8764±0.0184	0.8923±0.0160	0.8844±0.0163	0.9475±0.0033
SVM RBF	0.9226±0.0094	0.9232±0.0168	0.9223±0.0159	0.9241±0.0096	0.9682±0.0047
SVM POLYNOMIAL	0.9112±0.0089	0.9425±0.0103	0.8803±0.0196	0.9130±0.0092	0.9622±0.0046
KNN 3	0.8323±0.0130	0.8499±0.0187	0.8155±0.0247	0.8344±0.0143	0.8940±0.0145
KNN 5	0.8517±0.0142	0.8734±0.0181	0.8299±0.0239	0.8560±0.0148	0.9110±0.0113
MLP	0.9040±0.0117	0.9015±0.0202	0.9071±0.0189	0.9019±0.0134	0.9638±0.0083
XGBoost	0.8975±0.0100	0.9064±0.0171	0.8890±0.0138	0.8990±0.0088	0.9564±0.0072

Cuadro 7.45: Promedios y desviaciones estándar de las métricas ICH 3D

Discusión ICH En el cuadro 7.45 se observa que entre los modelos evaluados, el SVM RBF se destaca con un Accuracy del 92.26%, lo que sugiere una alta capacidad para realizar predicciones correctas. Este modelo también muestra un notable Sensitivity del 92.32%, indicando su eficacia en la identificación de casos positivos. En contraste, el SVM Polinomial presenta un Sensitivity aún mayor, del 94.25%, lo que resalta su habilidad para detectar correctamente una mayor proporción

de verdaderos positivos, aunque su Specificity se sitúa en 88.03 %, lo que podría señalar una mayor tasa de falsos positivos.

El modelo SVM Lineal, aunque presenta un Accuracy de 88.41 %, se caracteriza por un Specificity de 89.23 %, lo que implica que es efectivo en la identificación de casos negativos. Sin embargo, su Sensitivity de 87.64 % sugiere que podría mejorar en la detección de positivos. En el caso de los modelos KNN, el KNN 3 muestra el rendimiento más bajo entre los modelos evaluados, con un Accuracy de 83.23 %, lo que podría estar relacionado con su menor capacidad para discriminar entre las clases. Sin embargo, el KNN 5 mejora ligeramente estas métricas, alcanzando un Accuracy de 85.17 %.

El MLP y XGBoost presentan resultados competitivos, con el MLP alcanzando un Accuracy de 90.40 % y un AUC-ROC de 96.38 %, lo que propone una buena capacidad de discriminación. Por su parte, XGBoost se aproxima al rendimiento del MLP, mostrando un Accuracy de 89.75 % y un AUC-ROC de 95.64 %. En general, los modelos SVM, en particular el SVM RBF y SVM Polinomial, demuestran un rendimiento superior en comparación con los otros modelos, lo que indica su efectividad para abordar este problema de clasificación.

De acuerdo al cuadro 7.39 evidenciamos el mejor Accuracy alcanzado por el modelo ICH 3D, llegando al 94.03 %, el cual se generó con el clasificador SVM con kernel RBF.

7.2. Discusión general

El análisis de la arquitectura ResNet-18 3D mostró un rendimiento destacado, con el clasificador svm polinomial, obteniendo el mayor Accuracy promedio (0.9415) y AUC-ROC(0.9778), superando a otros clasificadores como KNN. ResNet-50 3D, aunque con menor rendimiento que ResNet-18 3D, mantuvo al svm polinomial como competitivo, mientras que KNN mostró un desempeño deficiente. DenseNet 3D presentó métricas más bajas en general, sugiriendo que podría no ser tan adecuada para este conjunto de datos, especialmente clasificando con KNN. DeepMultiScale 3D destacó con XGBoost logrando el segundo mejor Accuracy promedio(92.74 %) entre los modelos y AUC-ROC(97.08 %) seguido de resultados considerables con SVM. Finalmente, en ICH 3D, el SVM RBF fue el mejor clasificador, con un Accuracy de 92.26 % y un AUC-ROC de 96.82 %, mientras que KNN tuvo un rendimiento inferior, reafirmando su tendencia de bajo desempeño en estos modelos. En todas las arquitecturas, los clasificadores basados en SVM polinomial y RBF tienden a destacar en Sensitivity, lo que significa que son más efectivos en la detección de verdaderos positivos. Esto propone que estos modelos pueden ser preferidos en escenarios donde la detección de casos positivos es prioritaria. Aunque las Specificity son generalmente altas, hay una ligera tendencia a que los modelos SVM Lineal y KNN tiendan a tener mejores Specificity, especialmente en las arquitecturas de DeepMultiScale e ICH 3D. Estos modelos pueden ser más útiles cuando es crucial reducir los falsos positivos.

En cuanto a los mejores resultados logrados por cada modelo en una de las iteraciones de cada clasificador, se obtiene un Accuracy de 97.01 % para el modelo ResNet-18 3D con el clasificador XGBoost, llegando a un AUC-ROC casi de 1 con un 99.25 %, esta curva está ilustrada en la figura 7.8,

indicando el mejor desempeño entre los modelos para clasificar todas las instancias correctamente, enseguida los modelos DeepMultiScale 3D e ICH 3D se postulan como las dos opciones con un rendimiento cercano al mencionado anteriormente, en la figura 7.32 se ilustra la curva obtenida por el DeepMultiScale 3D y en la figura 7.35 se ilustra la curva obtenida por el ICH 3D, también podemos ver una leve predominancia en la clasificación de la clase normal.

Conclusiones

Este trabajo ha demostrado el potencial y la aplicabilidad de las técnicas de Deep Learning, particularmente las redes neuronales convolucionales (CNN), para la identificación automática de ataque cerebrovascular (ACV) isquémico en imágenes de tomografía computarizada (CT). La implementación de las arquitecturas ResNet18, ResNet50, DenseNet3D, DeepMultiScale 3D, e ICH 3D, permitió realizar un análisis comparativo de su rendimiento utilizando los clasificadores SVM, KNN, MLP y XGBoost. Estos clasificadores fueron seleccionados por su capacidad para manejar datos no lineales y clasificaciones complejas, características que resultan fundamentales para la detección de patrones isquémicos en las imágenes.

A lo largo del desarrollo del proyecto, se enfrentaron y abordaron diferentes desafíos asociados con la variabilidad de las imágenes CT, como la resolución, orientación y calidad de las mismas. El preprocesamiento y la normalización de los datos fueron pasos esenciales para mejorar la capacidad de los modelos para extraer características relevantes y mejorar la precisión de las predicciones. Asimismo, la evaluación del rendimiento de los modelos a través de métricas clave, como Accuracy, Sensitivity, Specificity, F1-score y AUC-ROC, permitió establecer una base sólida para determinar cuál arquitectura y clasificador se desempeñaba mejor en términos de balance entre Sensitivity y Specificity.

Entre los resultados más destacados encontramos el modelo Resnet18, el cual como extractor de características después de su respectivo entrenamiento y con el clasificador XGBoost obtiene el mejor Accuracy con un 97.01 % y AUC-ROC de 99.25 %, mostrando su gran desempeño para detectar casos de ACV isquémico y casos normales, se evidencia que los valores más altos en las métricas de evaluación se obtuvieron con los clasificadores XGBoost y SVM con kernel polinomial y Rbf, mostrando ser los mas robustos y adecuados para este problema, por otro lado el clasificador KNN fue menos efectivo en comparación con los otros. Los modelos ICH 3D y DeepMultiScale, presentaron también un buen desempeño, cercano al de Resnet18 3D, podemos ver que la Sensitivity tiene un valor promedio levemente mayor que la Specificity en la mayoría de las pruebas postulando estos tres modelos como las mejores arquitecturas para lidiar con el ACV isquémico sin descuidar los casos normales.

En términos de estabilidad, los clasificadores SVM Lineal y MLP tienden a ser los más consistentes a través de diferentes arquitecturas, con desviaciones estándar bajas en las principales métricas, especialmente en AUC-ROC. Esto sugiere que son modelos confiables en términos de rendimiento estable. Por otro lado, KNN ($k=3$ y $k=5$) muestra mayor variabilidad, lo que sugiere que su desempeño depende más del conjunto de datos particular y podría no ser tan robusto para generalizar en todas las arquitecturas.

Por otra parte, este estudio resalta la importancia de contar con un conjunto de datos adecuado y

equilibrado para entrenar los modelos de Deep Learning, dado que la falta de imágenes etiquetadas adecuadamente es uno de los principales retos para la implementación efectiva de estas tecnologías en un entorno clínico. La integración de datos de diferentes fuentes y su estandarización son fundamentales para mejorar la generalización de los modelos y su aplicabilidad en distintas poblaciones de pacientes.

En conclusión, este trabajo contribuye significativamente al campo del diagnóstico asistido por inteligencia artificial, proponiendo soluciones prácticas para la identificación automática de ACV isquémico en imágenes CT. Las técnicas de Deep Learning demostraron ser una herramienta valiosa para asistir a los profesionales de la salud en el diagnóstico temprano de esta patología, lo que podría reducir los tiempos de respuesta y mejorar los resultados clínicos de los pacientes afectados. Además, el uso de estas herramientas podría tener un impacto positivo en la optimización de los recursos en el sistema de salud, al reducir la carga sobre los radiólogos y acelerar los procesos de toma de decisiones.

Este estudio abre las puertas a futuros trabajos que podrían enfocarse en mejorar la integración de modelos de Deep Learning con sistemas de diagnóstico en tiempo real, así como explorar la combinación de datos multimodales, como resonancias magnéticas y otras técnicas de imagen, para mejorar la precisión diagnóstica en casos más complejos de ACV. Asimismo, se destaca la necesidad de seguir desarrollando algoritmos más interpretables que no solo ofrezcan predicciones precisas, sino también explicaciones claras de sus resultados, facilitando así su aceptación en entornos clínicos.

Trabajos futuros

1. **Aumento del tamaño del dataset:** Se sugiere ampliar el conjunto de datos mediante técnicas de aumento de datos (data augmentation) o establecer colaboraciones con instituciones de salud para obtener más imágenes de tomografía computarizada. Esto podría mejorar la capacidad del modelo para generalizar al enfrentarse a nuevos datos.
2. **Aplicación de técnicas de transfer learning:** Se podría aplicar transfer learning utilizando modelos preentrenados en datasets médicos grandes para optimizar el rendimiento del modelo en la tarea específica de detección de ACV.
3. **Preentrenamiento adicional en otras patologías similares:** Como alternativa, se sugiere realizar un preentrenamiento del modelo utilizando conjuntos de datos de otras patologías cerebrales, como hemorragias intracraneales u otros trastornos neurológicos, lo que podría permitir al modelo extraer características más relevantes para el reconocimiento del ACV.
4. **Desarrollo de una interfaz gráfica para la identificación y segmentación automática de ACV:** Una línea futura de investigación sería el desarrollo de una interfaz gráfica que permita a los usuarios cargar imágenes de tomografía computarizada en formato DICOM, transformarlas automáticamente al formato NRRD el cual es el que se está usando, y segmentar las áreas donde se sospeche la presencia de un ACV. Esta herramienta facilitaría el análisis en tiempo real y permitiría la adopción del sistema en entornos clínicos.
5. **Integración de la herramienta con sistemas PACS:** En un escenario clínico, la interfaz gráfica propuesta podría integrarse con los sistemas de almacenamiento y comunicación de imágenes médicas (PACS), lo que permitiría cargar y guardar imágenes directamente desde los servidores hospitalarios, optimizando los flujos de trabajo en hospitales y centros de diagnóstico para la detección de ACV.

CAPÍTULO 10

Anexos

**Anexo 1 Acuerdo de Confidencialidad - Investigaciones Clínicas -
Sebastián Hurtado Bustos**

OtroSi Acuerdo de Confidencialidad - Investigaciones Clínicas para SEBASTIAN HURTADO BUSTOS

Información del Ciudadano Lili

Nombres	SEBASTIAN	Área	IMAGENES DIAGNOSTICAS (10001564)
Apellidos	HURTADO BUSTOS	Cargo	PROFESIONAL EN PRACTICA EQUIPOS BIOMEDICOS (20003204)
Fecha de contratación	22/02/2024	ID del empleado	14534
Documento de identidad	1031540043		

Acuerdo Confidencialidad Investigaciones



ACUERDO DE CONFIDENCIALIDAD INVESTIGACIONES CLÍNICAS

Entre la **FUNDACION VALLE DEL LILI**, entidad sin ánimo de lucro, cuyo objeto es la prestación de servicios de salud, ubicada en Santiago de Cali, con NIT 890.324.177-5, con personería jurídica reconocida mediante resolución 6.337 de junio 21 de 1983, expedida por el Ministerio de Salud, quien en adelante y para los efectos del presente documento se denominará **LA FUNDACIÓN**, representada legalmente en este acto por **ALVARO QUINTERO CASTAÑO**, en su calidad de representante legal suplente, identificado con cédula de ciudadanía No. 10.250.125; y la persona igualmente mayor de edad relacionada en la sección INFORMACIÓN CIUDADANO LILI (parte superior de este documento) donde consta: nombres, apellidos, cargo y documento de identificación; y quien para efectos del presente acuerdo se denominará **EL RECEPTOR**, han acordado suscribir el presente Convenio de Confidencialidad y seguridad de la información, con el fin de que **EL RECEPTOR** pueda adelantar el proyecto de investigación. Este acuerdo se regirá por las definiciones y cláusulas que a continuación se enuncian:

DEFINICIONES

Para la adecuada interpretación del presente **ACUERDO DE CONFIDENCIALIDAD**, siempre que la letra inicial de los siguientes términos aparezca en mayúscula, tendrán el significado que se les atribuye a continuación. Así mismo, las definiciones de los términos aquí establecidos en singular y utilizados en plural tendrán el mismo significado y viceversa. Los términos que no sean expresamente definidos deberán entenderse de acuerdo con el sentido que les confiera el lenguaje técnico respectivo o por su significado y sentido natural y obvio, de conformidad con su uso general.

Información confidencial: Comprende, toda la información que fue suministrada por **LA FUNDACIÓN** a **EL RECEPTOR** en desarrollo de las reuniones, negociaciones, al igual que todos los análisis, estudios, notas, recopilaciones, resúmenes, memorandos, datos personales, informes y conclusiones o cualquier otro documento preparado por **EL RECEPTOR** que refleje la información que le haya sido suministrada o que haya sido preparada por los nombrados

anteriormente, al igual que cualquier idea, concepto, know how, conocimiento o técnica relacionada con las actividades propias del Centro de Investigaciones Clínicas de **LA FUNDACIÓN**. (ver PL-FVL-001_A)

Así mismo se entiende como Información Confidencial: (i) La información que no sea pública y sea conocida por **EL RECEPTOR** con ocasión del proyecto de investigación que pretende adelantar, bien sea que la misma sea presentada o entregada de forma escrita, oral o visual, y (ii) Cualquier información societaria, técnica, jurídica, financiera, comercial, de mercado, estratégica, de productos, nuevas tecnologías, datos personales de pacientes o participantes de estudios, modelos de negocios y cualquier otra actividad relacionada con las operaciones de estudios presentes y futuros de **LA FUNDACIÓN**, o relacionada con su estructura organizacional o de sus clientes, bien sea que la misma sea escrita, oral o visual, o en cualquier forma tangible o no, incluidos los Mensajes de Datos, de la cual **EL RECEPTOR** tenga conocimiento o a la que tenga acceso por cualquier medio o circunstancia en virtud de la relación existente entre Las Partes.

EL RECEPTOR: Se entenderá como la persona que suscribe el presente convenio de Confidencialidad en señal de aceptación y a quien **LA FUNDACIÓN** le entregará la Información Confidencial.

Negociaciones: se entenderá como los Tratos preliminares, prenegociales planes de trabajo, y/u ofertas mercantiles a las cuales se llegue entre las partes suscriptoras del presente acuerdo.

Dato personal: Cualquier información vinculada o que pueda asociarse a una o varias personas naturales determinadas o determinables.

Datos sensibles: Se entiende por datos sensibles aquellos que afectan la intimidad del titular o cuyo uso indebido puede generar su discriminación, tales como aquellos que revelen el origen racial o étnico, la orientación política, las convicciones religiosas o filosóficas, la pertenencia a sindicatos, organizaciones sociales, de derechos humanos o que promueva intereses de cualquier partido político o que garanticen los derechos y garantías de partidos políticos de oposición, así como los datos relativos a la salud, a la vida sexual, los datos biométricos, datos materiales y la historia clínica, los cuales solo se recolectarán, incorporarán y/o almacenarán con autorización previa del titular de la información, y cuando sea necesaria para la ejecución de la relación contractual con el titular, siempre y cuando la ley permita acceder a dicha información. Por tanto, el acceso, circulación y tratamiento de los datos sensibles será restringido y limitado a la autorización del titular y a lo estipulado en la normativa vigente.

Tratamiento: Cualquier operación o conjunto de operaciones sobre datos personales, tales como la recolección, almacenamiento, uso, circulación o supresión.

Responsable del tratamiento: Persona natural o jurídica, pública o privada, que por sí misma o en asocio con otros, decida sobre la base de datos y/o el tratamiento de los datos.

Titular: Persona natural cuyos datos personales sean objeto de tratamiento.

Base de datos: Conjunto organizado de datos personales que sea objeto de tratamiento.

Anonimización: Es el proceso por el cual la información de identificación personal se modifica de forma irreversible de tal manera que el responsable del tratamiento, o cualquier tercero, no puede identificar, directa o indirectamente, a la persona asociada a dicha información de identificación personal.

CLÁUSULAS

CLÁUSULA PRIMERA. - MANEJO DE LA INFORMACIÓN CONFIDENCIAL: EL RECEPTOR reconoce de manera expresa, la naturaleza confidencial de toda la Información que le suministre **LA FUNDACIÓN** y el hecho de que es de su propiedad exclusiva. En consecuencia, **EL RECEPTOR** acepta y está de acuerdo en que:

- 1.) Sólo utilizará la Información Confidencial con el propósito exclusivo de cumplir con las finalidades acordadas, específicamente las relacionadas con el objeto del contrato.
- 2.) No permitirá el acceso a la Información Confidencial ni divulgará de manera parcial o total su contenido a ningún tercero, en especial del sector de la Salud, sin el consentimiento escrito previo de **LA FUNDACIÓN**.

CLÁUSULA SEGUNDA. - INFORMACION NO SUJETA CONFIDENCIALIDAD O RESERVA: Se excluye de los efectos de este Convenio aquella información no sujeta a confidencialidad y reserva que:

- 1.) Al momento de ser revelada sea ya de dominio público, o que, luego de dicha revelación, se convierta de dominio público por causas no imputables a **EL RECEPTOR**, para lo cual, se entenderá que es de dominio público la información que aparezca en una fuente de divulgación de libre acceso al público en general.
- 2.) Cuando su publicidad sea requerida de acuerdo con las leyes vigentes o por virtud de orden escrita de autoridad competente, evento en el cual **EL RECEPTOR** comunicará inmediatamente por escrito de esta situación a **LA FUNDACIÓN** para que ésta pueda tomar las medidas necesarias para oponerse a dicha petición adelantando las acciones judiciales o administrativas que sean del caso, colaborando con ésta en todo aquello que esté a su alcance para proteger y mantener la reserva de dicha Información Confidencial.
- 3.) Al momento en que **LA FUNDACIÓN** autorice expresamente a divulgar la información por un medio escrito a **EL RECEPTOR**.

CLÁUSULA TERCERA. - OBLIGACIONES DE EL RECEPTOR: **EL RECEPTOR** encargado de la Información Confidencial se obliga a dar cumplimiento a la política de seguridad de la información de **LA FUNDACION**, y a mantener estricta confidencialidad sobre la documentación e información que conozca, produzca, reciba, o intercambie con ocasión al objeto del contrato o lo que llegará a conocer en virtud del mismo.

1. Proteger la confidencialidad de la información verbal, escrita o que por cualquier otro medio reciba de **LA FUNDACIÓN** restringiendo su uso exclusivamente a sus Representantes que tengan absoluta necesidad de conocerla y en beneficio de las negociaciones.
2. Usar toda la Información Confidencial que le entregue **LA FUNDACIÓN** o un tercero como parte del desarrollo del proyecto de investigación que pretende adelantar solamente para efectos anotados en el presente documento o para cumplir con las obligaciones que se pacten en virtud de la relación comercial. Igualmente, se obliga a mantener dicha información en reserva hasta tanto adquiera carácter público.
3. Garantizar que las personas que tengan acceso a la Información Confidencial reconozcan su carácter confidencial. En consecuencia, se obliga a seguir las políticas y pautas establecidas por la institución en cabeza de la Subdirección de Informática para el debido manejo de la información
4. En caso de existir duda en cuanto si alguna información es un secreto comercial o información Confidencial o sensible y esta se encuentra sujeta a los términos del presente acuerdo de voluntades, deberá de ser tratada como confidencial y, por ende, estará sujeta a los términos de este convenio.
5. Proteger estrictamente la Información Confidencial o sensible que reciba de **LA FUNDACIÓN**, acatando las medidas de seguridad establecidas por la Subdirección de Informática para evitar su divulgación, pérdida, adulteración, uso fraudulento o no adecuado, o cualquier otro incumplimiento a sus obligaciones generales o específicas en el marco del presente contrato.
6. Reportar a **la FUNDACIÓN** al equipo de ciberseguridad al correo ciberseguridad@fvf.org.co y al área de Protección de Datos personales al correo: datospersonales@fvf.org.co los incidentes de seguridad informática y de la información que se presenten con la Información (física y digital) y/o los equipos tecnológicos inmediatamente después de que se identifique la ocurrencia del incidente.
7. Se obliga a no recolectar **datos personales ni sensibles** adicionales con base a la **Información Confidencial** a la que tenga acceso, y a no realizar cruces de información que permitan adicionar los datos transferidos, ni a enajenar o negociar a título alguno la información.

CLÁUSULA CUARTA. DURACIÓN: El presente Convenio de Confidencialidad estará vigente de manera indefinida, motivo por el cual, **EL RECEPTOR** no podrá divulgar la Información

Confidencial en ningún tiempo.

CLÁUSULA QUINTA. - DEVOLUCION DE LA INFORMACION: En caso de terminación del contrato por cualquier causa o terminación del objeto del contrato, **EL RECEPTOR** se obliga, a reintegrar o destruir, según le solicite **LA FUNDACIÓN** por cualquier medio, toda la documentación e información que le haya sido suministrada y todo otro material o documento que incorpore o refleje Información Confidencial, a la que haya tenido acceso y que conserve **EL RECEPTOR**. La entrega de la documentación se deberá efectuar en un plazo no mayor a Cinco (5) días calendarios siguientes a la solicitud de entrega de tal documentación por parte de **LA FUNDACIÓN**. Igualmente, cualquier Información Confidencial mantenida en computadoras, medios magnéticos o cualquier otro similar, será destruida si así es requerido por **LA FUNDACIÓN**. Una vez devuelta y destruida la mencionada documentación, **EL RECEPTOR** hará constar mediante comunicación escrita que no se encuentra en su poder ningún otro documento sujeto a la obligación de confidencialidad aquí establecida.

CLÁUSULA SEXTA. CLÁUSULA PENAL: EL RECEPTOR se compromete a resarcir todos los perjuicios o daños que, con ocasión al objeto del contrato, llegará a ocasionar como consecuencia del incumplimiento de este Convenio de Confidencialidad y de las demás obligaciones anteriormente descritas.

PARAGRAFO: No obstante, lo anterior, **EL RECEPTOR** acepta y reconoce que el pago de la pena aquí pactada no será suficiente para cubrir los perjuicios que resulten de la violación del presente Acuerdo por parte suya. En consecuencia, **LA FUNDACIÓN** podrá perseguir la indemnización de perjuicios y ejercer cualquier medio legal para evitar que se sigan ocasionando perjuicios como consecuencia de la violación.

CLÁUSULA SEPTIMA. PROPIEDAD DE LA INFORMACIÓN: LAS PARTES acuerdan que en virtud del presente contrato no se transfiere la propiedad de ninguna Información **en especial de la Confidencial, ni de la Sensible**, ni de la que se encuentra en la **Base de Datos de LA FUNDACION a EL RECEPTOR**; perpetuamente continuarán siendo de los **Titulares** y de **LA FUNDACIÓN** respectivamente.

CLÁUSULA OCTAVA. NO RENUNCIA A DERECHOS: La falta o demora de **LA FUNDACIÓN** en ejercer cualquiera de las facultades o derechos consagrados en el presente Convenio de Confidencialidad, o a exigir su cumplimiento, no se interpretará como una renuncia a dichos derechos o facultades ni afectará la validez, total o parcial del Convenio, ni el derecho de ejercer posteriormente tales facultades o derechos, salvo disposición legal o contractual en contrario.

CLAUSULA NOVENA. NO CESION DEL CONVENIO: EL RECEPTOR no podrá ceder el presente Convenio.

CLAUSULA DÉCIMA. TRANSMISIÓN Y/O TRANSFERENCIA DE DATOS PERSONALES Y/O SENSIBLES: EL RECEPTOR no podrá transferir ni transmitir ningún tipo de dato e información hacia partes interesadas externas que no estén aprobadas por **LA FUNDACION** o que no hagan parte esencial de este contrato y su cláusula de confidencialidad, así como el cumplimiento a la normatividad legal vigente en materia de transmisión y transferencia internacional de datos personales. En caso de requerirse esta actividad, se deberá utilizar canales seguros y cifrados salvaguardando la confidencialidad e integridad de la información. No se podrán utilizar medios de comunicación No autorizados por **LA FUNDACIÓN** como herramientas como W-transfer, Google Drive, DropBox, WhatsApp, redes sociales, entre otras.

CLAUSULA UNDÉCIMA SEGURIDAD DE LA INFORMACIÓN Y PROTECCIÓN DE DATOS PERSONALES Y SENSIBLES:

a) Datos Personales: De acuerdo con lo dispuesto en la Ley 1581/2012, de Protección de Datos Personales, ambas partes se obligan a garantizar, el cumplimiento de esta Ley y de su Reglamento por el Decreto 1377/2013, así como la política de privacidad de datos de la Fundación valle del Lili (AN-FVL-071) garantizando que los datos personales a los cuales se podrá tener acceso en la relación contractual estarán salvaguardados y no podrán ser copiados, modificados, ni eliminados, ni divulgados sin autorización del titular, tampoco

usados para fines diferentes a lo autorizado en esta relación contractual

b) Seguridad de la información: **EL RECEPTOR** se compromete a cumplir con las políticas de seguridad de la información establecidas por **LA FUNDACIÓN**, así mismo a salvaguardar toda información relacionada con el proyecto de investigación que pretende adelantar; además de ello se compromete a:

- No realizar ninguna copia o distribución de información sensible o confidencial que pueda llegar a obtener durante la ejecución de este contrato, sin previa autorización de Fundación Valle del Lili.

- Usar adecuadamente los equipos tecnológicos, así como las herramientas corporativas que **LA FUNDACIÓN** le pueda otorgar para el ejercicio de la relación comercial para con **LA FUNDACIÓN**.

- No utilizar dispositivos de almacenamiento externos, con la finalidad de transportar, almacenar y/o compartir información sensible o confidencial de **LA FUNDACIÓN**, salvo autorización de jefe inmediato y revisado por el área de ciberseguridad de **LA FUNDACIÓN**.

- Adoptar las medidas de seguridad de la información que garanticen la confidencialidad y no divulgación de la información sensible o confidencial entregada por parte de la Fundación Valle del Lili o que se pueda generar en la relación contractual entre **EL RECEPTOR**, teniendo presente mantener un alto nivel de cuidado, para evitar su pérdida, robo o sustracción o divulgación no autorizada.

- A no realizar ningún tipo de alteración y modificación al hardware y software de los equipos tecnológicos que pertenezcan a **LA FUNDACIÓN**.

- Adoptar las medidas de seguridad de la información que garanticen la confidencialidad y no divulgación de la información sensible o confidencial entregada por parte de la Fundación Valle del Lili o que se pueda generar en la relación contractual entre **EL RECEPTOR** teniendo presente mantener un alto nivel de cuidado, para evitar su pérdida, robo o sustracción o divulgación no autorizada.

- En sitios externos a alguna de las sedes de la Fundación Valle del Lili presentes y futuras, no utilizar redes WIFI o LAN (cable) gratuitas y/o públicas que puedan afectar la Confidencialidad, Integridad y Disponibilidad de la información.

- Utilizar las herramientas de seguridad y protocolos de cifrado de información definidos por **LA FUNDACIÓN** para la transferencia de todo tipo de información, y usar solo aplicaciones corporativas para tal fin según nuestra política de USO ACEPTABLE DE LA TECNOLOGÍA INFORMÁTICA AN-INF-003.

- Abstenerse del uso de herramientas que no sean institucionales (WhatsApp, Line, Google Drive, Dropbox, entre otras) que comprometan la Confidencialidad, Privacidad e Integridad de la Información.

- Cumplir a cabalidad cualquier lineamiento y política de seguridad de la información que **LA FUNDACIÓN** crea pertinente implementar para salvaguardar la Confidencialidad, Integridad, Disponibilidad de la información.

- Destruir cualquier copia de información no autorizada por **LA FUNDACIÓN**, al terminar la relación contractual.

-Las demás previstas por la Ley Colombiana.

A continuación, las partes manifiestan que han leído y estudiado de manera detenida los términos y el contenido de este Convenio de Confidencialidad, al igual que aceptan todas sus condiciones y firman electrónicamente como constancia del acuerdo.

Por **LA FUNDACIÓN**.



ÁLVARO QUINTERO CASTAÑO
C.C. 10.250.125 de Manizales
Representante Legal Suplente
FUNDACIÓN VALLE DEL LILI

Acepto los términos de esta cláusula de confidencialidad Si

Firma de Aceptación

Ciudadano Lili: SEBASTIAN HURTADO BUSTOS

14/06/2024

**Anexo 2 – Acuerdo de Confidencialidad - Investigaciones Clínicas -
Santiago Valencia Amaya**

ACUERDO DE CONFIDENCIALIDAD

Entre la **FUNDACION VALLE DEL LILI**, entidad sin ánimo de lucro, cuyo objeto es la prestación de servicios de salud, ubicada en Santiago de Cali, con NIT 890.324.177-5, con personería jurídica reconocida mediante resolución 6.337 de junio 21 de 1983, expedida por el Ministerio de Salud, quien en adelante y para los efectos del presente documento se denominará **LA FUNDACIÓN y SANTIAGO VALENCIA AMAYA, igualmente mayor de edad, identificado con cédula de ciudadanía No. 1005892715**, quien para efectos del presente acuerdo se denominará **EL RECEPTOR**, han acordado suscribir el presente Convenio de Confidencialidad y seguridad de la información, con el fin de que **EL RECEPTOR** pueda adelantar el proyecto denominado **2024.157/ IDENTIFICACIÓN AUTOMÁTICA DE ATAQUE CEREBROVASCULAR (ACV) ISQUÉMICO MEDIANTE LA APLICACIÓN DE TÉCNICAS DE DEEP LEARNING EN IMÁGENES DE TOMOGRAFÍA COMPUTARIZADA** (en adelante “El Proyecto”). Este acuerdo se regirá por las definiciones y cláusulas que a continuación se enuncian:

DEFINICIONES

Para la adecuada interpretación del presente **ACUERDO DE CONFIDENCIALIDAD**, siempre que la letra inicial de los siguientes términos aparezca en mayúscula, tendrán el significado que se les atribuye a continuación. Así mismo, las definiciones de los términos aquí establecidos en singular y utilizados en plural tendrán el mismo significado y viceversa. Los términos que no sean expresamente definidos deberán entenderse de acuerdo con el sentido que les confiera el lenguaje técnico respectivo o por su significado y sentido natural y obvio, de conformidad con su uso general.

Información Confidencial: Comprende, toda la información que fue suministrada por **LA FUNDACIÓN** a **EL RECEPTOR** en desarrollo de las reuniones, negociaciones, al igual que todos los análisis, estudios, notas, recopilaciones, resúmenes, memorandos, datos personales, informes y conclusiones o cualquier otro documento o archivo de cualquier clase preparado por **EL RECEPTOR** que refleje la información que le haya sido suministrada o que haya sido preparada por los nombrados anteriormente, al igual que cualquier idea, concepto, know how, conocimiento o técnica relacionada con las actividades propias de **LA FUNDACIÓN** y cualquiera de sus servicios o áreas. (ver PL-FVL-001_A)

Así mismo se entiende como Información Confidencial: (i) La información que no sea pública y sea conocida por **EL RECEPTOR** con ocasión de El Proyecto que pretende adelantar, bien sea que la misma sea presentada o entregada de forma escrita, oral o visual, y (ii) Cualquier información societaria, técnica, jurídica, financiera, comercial, de mercado, estratégica, de productos, nuevas tecnologías, datos personales de pacientes o participantes de estudios, modelos de negocios y cualquier otra actividad relacionada con las operaciones de estudios presentes y futuros de **LA FUNDACIÓN**, o relacionada con su estructura organizacional o de sus clientes, bien sea que la misma sea escrita, oral o visual, o en cualquier forma tangible o

no, incluidos los Mensajes de Datos, de la cual **EL RECEPTOR** tenga conocimiento o a la que tenga acceso por cualquier medio o circunstancia en virtud de la relación existente entre Las Partes.

EL RECEPTOR: Se entenderá como la persona que suscribe el presente convenio de Confidencialidad en señal de aceptación y a quien **LA FUNDACIÓN** le entregará la Información Confidencial.

Negociaciones: se entenderá como los Tratos preliminares, prenegociales planes de trabajo, y/u ofertas mercantiles a las cuales se llegue entre las partes suscriptoras del presente acuerdo.

Dato personal: Cualquier información vinculada o que pueda asociarse a una o varias personas naturales determinadas o determinables.

Datos sensibles: Se entiende por datos sensibles aquellos que afectan la intimidad del titular o cuyo uso indebido puede generar su discriminación, tales como aquellos que revelen el origen racial o étnico, la orientación política, las convicciones religiosas o filosóficas, la pertenencia a sindicatos, organizaciones sociales, de derechos humanos o que promueva intereses de cualquier partido político o que garanticen los derechos y garantías de partidos políticos de oposición, así como los datos relativos a la salud, a la vida sexual, los datos biométricos, datos materiales y la historia clínica, los cuales solo se recolectarán, incorporarán y/o almacenarán con autorización previa del titular de la información, y cuando sea necesaria para la ejecución de la relación contractual con el titular, siempre y cuando la ley permita acceder a dicha información. Por tanto, el acceso, circulación y tratamiento de los datos sensibles será restringido y limitado a la autorización del titular y a lo estipulado en la normativa vigente.

Tratamiento: Cualquier operación o conjunto de operaciones sobre datos personales, tales como la recolección, almacenamiento, uso, circulación o supresión.

Responsable del tratamiento: Persona natural o jurídica, pública o privada, que por sí misma o en asocio con otros, decida sobre la base de datos y/o el tratamiento de los datos.

Titular: Persona natural cuyos datos personales sean objeto de tratamiento.

Base de datos: Conjunto organizado de datos personales que sea objeto de tratamiento.

Anonimización: Es el proceso por el cual la información de identificación personal se modifica de forma irreversible de tal manera que el responsable del tratamiento, o cualquier tercero, no puede identificar, directa o indirectamente, a la persona asociada a dicha información de identificación personal.

CLÁUSULAS

CLÁUSULA PRIMERA. - MANEJO DE LA INFORMACIÓN CONFIDENCIAL: EL RECEPTOR

reconoce de manera expresa, la naturaleza confidencial de toda la Información que le suministre **LA FUNDACIÓN** y el hecho de que es de su propiedad exclusiva. En consecuencia, **EL RECEPTOR** acepta y está de acuerdo en que:

- 1.) Sólo utilizará la Información Confidencial con el propósito exclusivo de cumplir con las finalidades acordadas, específicamente las relacionadas con el objeto del contrato.
- 2.) No permitirá el acceso a la Información Confidencial ni divulgará de manera parcial o total su contenido a ningún tercero, en especial del sector de la Salud, sin el consentimiento escrito previo de **LA FUNDACIÓN**.

CLÁUSULA SEGUNDA. - INFORMACION NO SUJETA CONFIDENCIALIDAD O RESERVA:

Se excluye de los efectos de este Convenio aquella información no sujeta a confidencialidad y reserva que:

- 1.) Al momento de ser revelada sea ya de dominio público, o que, luego de dicha revelación, se convierta de dominio público por causas no imputables a **EL RECEPTOR**, para lo cual, se entenderá que es de dominio público la información que aparezca en una fuente de divulgación de libre acceso al público en general.
- 2.) Cuando su publicidad sea requerida de acuerdo con las leyes vigentes o por virtud de orden escrita de autoridad competente, evento en el cual **EL RECEPTOR** comunicará inmediatamente por escrito de esta situación a **LA FUNDACIÓN** para que ésta pueda tomar las medidas necesarias para oponerse a dicha petición adelantando las acciones judiciales o administrativas que sean del caso, colaborando con ésta en todo aquello que esté a su alcance para proteger y mantener la reserva de dicha Información Confidencial.
- 3.) Al momento en que **LA FUNDACIÓN** autorice expresamente a divulgar la información por un medio escrito a **EL RECEPTOR**.

CLÁUSULA TERCERA. - OBLIGACIONES DE EL RECEPTOR: EL RECEPTOR encargado de la Información Confidencial se obliga a dar cumplimiento a la política de seguridad de la información de **LA FUNDACION**, y a mantener estricta confidencialidad sobre la documentación e información que conozca, produzca, reciba, o intercambie con ocasión al objeto del contrato o lo que llegará a conocer en virtud del mismo.

1. Proteger la confidencialidad de la información verbal, escrita o que por cualquier otro medio reciba de **LA FUNDACIÓN** restringiendo su uso exclusivamente a sus Representantes que tengan absoluta necesidad de conocerla y en beneficio de las negociaciones.
2. Usar toda la Información Confidencial que le entregue **LA FUNDACIÓN** o un tercero como parte del desarrollo de El Proyecto que pretende adelantar solamente para efectos anotados en el presente documento o para cumplir con las obligaciones que se pacten en virtud de la relación comercial. Igualmente, se obliga a mantener dicha información en reserva hasta tanto adquiera carácter público.
3. Garantizar que las personas que tengan acceso a la Información Confidencial reconozcan su carácter confidencial. En consecuencia, se obliga a seguir las políticas y pautas establecidas por la institución en cabeza de la Subdirección de Informática para el debido manejo de la información
4. En caso de existir duda en cuanto si alguna información es un secreto comercial o información Confidencial o sensible y esta se encuentra sujeta a los términos del

presente acuerdo de voluntades, deberá de ser tratada como confidencial y, por ende, estará sujeta a los términos de este convenio.

5. Proteger estrictamente la Información Confidencial o sensible que reciba de **LA FUNDACIÓN**, acatando las medidas de seguridad establecidas por la Subdirección de Informática para evitar su divulgación, pérdida, adulteración, uso fraudulento o no adecuado, o cualquier otro incumplimiento a sus obligaciones generales o específicas en el marco del presente contrato.
6. Reportar a la FUNDACIÓN al equipo de ciberseguridad al correo ciberseguridad@fvl.org.co y al área de Protección de Datos personales al correo: datospersonales@fvl.org.co los incidentes de seguridad informática y de la información que se presenten con la Información (física y digital) y/o los equipos tecnológicos inmediatamente después de que se identifique la ocurrencia del incidente.
7. Se obliga a no recolectar **datos personales ni sensibles** adicionales con base a la **Información Confidencial** a la que tenga acceso, y a no realizar cruces de información que permitan adicionar los datos transferidos, ni a enajenar o negociar a título alguno la información.

CLÁUSULA CUARTA. DURACIÓN: El presente Convenio de Confidencialidad estará vigente de manera indefinida, motivo por el cual, **EL RECEPTOR** no podrá divulgar la Información Confidencial en ningún tiempo.

CLÁUSULA QUINTA. - DEVOLUCION DE LA INFORMACION: En caso de terminación del contrato por cualquier causa o terminación del objeto del contrato, **EL RECEPTOR** se obliga, a reintegrar o destruir, según le solicite **LA FUNDACIÓN** por cualquier medio, toda la documentación e información que le haya sido suministrada y todo otro material o documento que incorpore o refleje Información Confidencial, a la que haya tenido acceso y que conserve **EL RECEPTOR**. La entrega de la documentación se deberá efectuar en un plazo no mayor a Cinco (5) días calendarios siguientes a la solicitud de entrega de tal documentación por parte de **LA FUNDACIÓN**. Igualmente, cualquier Información Confidencial mantenida en computadoras, medios magnéticos o cualquier otro similar, será destruida si así es requerido por **LA FUNDACIÓN**. Una vez devuelta y destruida la mencionada documentación, **EL RECEPTOR** hará constar mediante comunicación escrita que no se encuentra en su poder ningún otro documento sujeto a la obligación de confidencialidad aquí establecida.

CLÁUSULA SEXTA. CLÁUSULA PENAL: EL RECEPTOR se compromete a resarcir todos los perjuicios o daños que, con ocasión al objeto del contrato, llegará a ocasionar como consecuencia del incumplimiento de este Convenio de Confidencialidad y de las demás obligaciones anteriormente descritas.

PARAGRAFO: No obstante, lo anterior, **EL RECEPTOR** acepta y reconoce que el pago de la pena aquí pactada no será suficiente para cubrir los perjuicios que resulten de la violación del presente Acuerdo por parte suya. En consecuencia, **LA FUNDACIÓN** podrá perseguir la indemnización de perjuicios y ejercer cualquier medio legal para evitar que se sigan ocasionando perjuicios como consecuencia de la violación.

CLÁUSULA SEPTIMA. PROPIEDAD DE LA INFORMACIÓN: LAS PARTES acuerdan que en

virtud del presente contrato no se transfiere la propiedad de ninguna Información **en especial de la Confidencial, ni de la Sensible**, ni de la que se encuentra en la **Base de Datos de LA FUNDACION a EL RECEPTOR**; perpetuamente continuarán siendo de los **Titulares** y de **LA FUNDACIÓN** respectivamente.

CLÁUSULA OCTAVA. NO RENUNCIA A DERECHOS: La falta o demora de **LA FUNDACIÓN** en ejercer cualquiera de las facultades o derechos consagrados en el presente Convenio de Confidencialidad, o a exigir su cumplimiento, no se interpretará como una renuncia a dichos derechos o facultades ni afectará la validez, total o parcial del Convenio, ni el derecho de ejercer posteriormente tales facultades o derechos, salvo disposición legal o contractual en contrario.

CLAUSULA NOVENA. NO CESION DEL CONVENIO: EL RECEPTOR no podrá ceder el presente Convenio.

CLAUSULA DÉCIMA. TRANSMISIÓN Y/O TRANSFERENCIA DE DATOS PERSONALES Y/O SENSIBLES: EL RECEPTOR no podrá transferir ni transmitir ningún tipo de dato e información hacia partes interesadas externas que no estén aprobadas por **LA FUNDACION** o que no hagan parte esencial de este contrato y su cláusula de confidencialidad, así como el cumplimiento a la normatividad legal vigente en materia de transmisión y transferencia internacional de datos personales. En caso de requerirse esta actividad, se deberá utilizar canales seguros y cifrados salvaguardando la confidencialidad e integridad de la información. No se podrán utilizar medios de comunicación No autorizados por **LA FUNDACIÓN** como herramientas como W-transfer, Google Drive, DropBox, WhatsApp, redes sociales, entre otras.

CLAUSULA UNDÉCIMA SEGURIDAD DE LA INFORMACIÓN Y PROTECCIÓN DE DATOS PERSONALES Y SENSIBLES:

- a) Datos Personales: De acuerdo con lo dispuesto en la Ley 1581/2012, de Protección de Datos Personales, ambas partes se obligan a garantizar, el cumplimiento de esta Ley y de su Reglamento por el Decreto 1377/2013, así como la política de privacidad de datos de la Fundación valle del Lili (AN-FVL-071) garantizando que los datos personales a los cuales se podrá tener acceso en la relación contractual estarán salvaguardados y no podrán ser copiados, modificados, ni eliminados, ni divulgados sin autorización del titular, tampoco usados para fines diferentes a lo autorizado en esta relación contractual
- b) Seguridad de la información: **EL RECEPTOR** se compromete a cumplir con las políticas de seguridad de la información establecidas por **LA FUNDACIÓN**, así mismo a salvaguardar toda información relacionada con El Proyecto que pretende adelantar; además de ello se compromete a:
 - No realizar ninguna copia o distribución de información sensible o confidencial que pueda llegar a obtener durante la ejecución de este contrato, sin previa autorización de **LA FUNDACIÓN**.
 - Usar adecuadamente los equipos tecnológicos así como las herramientas corporativas que **LA FUNDACIÓN** le pueda otorgar para el ejercicio de la relación comercial para con **LA FUNDACIÓN**.

- No utilizar dispositivos de almacenamiento externos, con la finalidad de transportar, almacenar y/o compartir información sensible o confidencial de **LA FUNDACIÓN**, salvo autorización de jefe inmediato y revisado por el área de ciberseguridad de **LA FUNDACIÓN**.
- A no realizar ningún tipo de alteración y modificación al hardware y software de los equipos tecnológicos que pertenezcan a **LA FUNDACIÓN**.
- Adoptar las medidas de seguridad de la información que garanticen la confidencialidad y no divulgación de la información sensible o confidencial entregada por parte de **LA FUNDACIÓN** o que se pueda generar en la relación contractual entre **EL RECEPTOR** y **LA FUNDACIÓN**, teniendo presente mantener un alto nivel de cuidado, para evitar su pérdida, robo o sustracción o divulgación no autorizada.
- En sitios externos a alguna de las sedes de **LA FUNDACIÓN** presentes y futuras, no utilizar redes WIFI o LAN (cable) gratuitas y/o públicas que puedan afectar la Confidencialidad, Integridad y Disponibilidad de la información.
- Utilizar las herramientas de seguridad y protocolos de cifrado de información definidos por **LA FUNDACIÓN** para la transferencia de todo tipo de información, y usar solo aplicaciones corporativas para tal fin según nuestra política de USO ACEPTABLE DE LA TECNOLOGÍA INFORMÁTICA AN-INF-003.
- Abstenerse del uso de herramientas que no sean institucionales (WhatsApp, Line, Google Drive, Dropbox, entre otras) que comprometan la Confidencialidad, Privacidad e Integridad de la Información.
- Cumplir a cabalidad cualquier lineamiento y política de seguridad de la información que **LA FUNDACIÓN** crea pertinente implementar para salvaguardar la Confidencialidad, Integridad, Disponibilidad de la información.
- Destruir cualquier copia de información no autorizada por **LA FUNDACION**, al terminar la relación contractual.
- Las demás previstas por la Ley Colombiana

A continuación, **EL RECEPTOR** manifiesta que ha leído y estudiado de manera detenida los términos y el contenido de este Convenio de Confidencialidad, al igual que acepta todas sus condiciones y firma electrónicamente como constancia del acuerdo.

EL RECEPTOR

Santiago Valencia A

Santiago Valencia Amaya
C.C 1005892715 de Cali
Fecha: 28/06/2024

**Anexo 3 – Acuerdo de Confidencialidad - Investigaciones Clínicas -
Hernán Darío Vargas Cardona**

ACUERDO DE CONFIDENCIALIDAD

Entre la **FUNDACION VALLE DEL LILI**, entidad sin ánimo de lucro, cuyo objeto es la prestación de servicios de salud, ubicada en Santiago de Cali, con NIT 890.324.177-5, con personería jurídica reconocida mediante resolución 6.337 de junio 21 de 1983, expedida por el Ministerio de Salud, quien en adelante y para los efectos del presente documento se denominará **LA FUNDACIÓN** y **HERNAN DARIO VARGAS CARDONA**, igualmente mayor de edad, identificado con cédula de ciudadanía No. 1097721437, quien para efectos del presente acuerdo se denominará **EL RECEPTOR**, han acordado suscribir el presente Convenio de Confidencialidad y seguridad de la información, con el fin de que **EL RECEPTOR** pueda adelantar el proyecto denominado **2024.157/ IDENTIFICACIÓN AUTOMÁTICA DE ATAQUE CEREBROVASCULAR (ACV) ISQUÉMICO MEDIANTE LA APLICACIÓN DE TÉCNICAS DE DEEP LEARNING EN IMÁGENES DE TOMOGRAFÍA COMPUTARIZADA** (en adelante “El Proyecto”). Este acuerdo se regirá por las definiciones y cláusulas que a continuación se enuncian:

DEFINICIONES

Para la adecuada interpretación del presente **ACUERDO DE CONFIDENCIALIDAD**, siempre que la letra inicial de los siguientes términos aparezca en mayúscula, tendrán el significado que se les atribuye a continuación. Así mismo, las definiciones de los términos aquí establecidos en singular y utilizados en plural tendrán el mismo significado y viceversa. Los términos que no sean expresamente definidos deberán entenderse de acuerdo con el sentido que les confiera el lenguaje técnico respectivo o por su significado y sentido natural y obvio, de conformidad con su uso general.

Información Confidencial: Comprende, toda la información que fue suministrada por **LA FUNDACIÓN** a **EL RECEPTOR** en desarrollo de las reuniones, negociaciones, al igual que todos los análisis, estudios, notas, recopilaciones, resúmenes, memorandos, datos personales, informes y conclusiones o cualquier otro documento o archivo de cualquier clase preparado por **EL RECEPTOR** que refleje la información que le haya sido suministrada o que haya sido preparada por los nombrados anteriormente, al igual que cualquier idea, concepto, know how, conocimiento o técnica relacionada con las actividades propias de **LA FUNDACIÓN** y cualquiera de sus servicios o áreas. (ver PL-FVL-001_A)

Así mismo se entiende como Información Confidencial: (i) La información que no sea pública y sea conocida por **EL RECEPTOR** con ocasión de El Proyecto que pretende adelantar, bien sea que la misma sea presentada o entregada de forma escrita, oral o visual, y (ii) Cualquier información societaria, técnica, jurídica, financiera, comercial, de mercado, estratégica, de productos, nuevas tecnologías, datos personales de pacientes o participantes de estudios, modelos de negocios y cualquier otra actividad relacionada con las operaciones de estudios presentes y futuros de **LA FUNDACIÓN**, o relacionada con su estructura organizacional o de sus clientes, bien sea que la misma sea escrita, oral o visual, o en cualquier forma tangible o

no, incluidos los Mensajes de Datos, de la cual **EL RECEPTOR** tenga conocimiento o a la que tenga acceso por cualquier medio o circunstancia en virtud de la relación existente entre Las Partes.

EL RECEPTOR: Se entenderá como la persona que suscribe el presente convenio de Confidencialidad en señal de aceptación y a quien **LA FUNDACIÓN** le entregará la Información Confidencial.

Negociaciones: se entenderá como los Tratos preliminares, prenegociales planes de trabajo, y/u ofertas mercantiles a las cuales se llegue entre las partes suscriptoras del presente acuerdo.

Dato personal: Cualquier información vinculada o que pueda asociarse a una o varias personas naturales determinadas o determinables.

Datos sensibles: Se entiende por datos sensibles aquellos que afectan la intimidad del titular o cuyo uso indebido puede generar su discriminación, tales como aquellos que revelen el origen racial o étnico, la orientación política, las convicciones religiosas o filosóficas, la pertenencia a sindicatos, organizaciones sociales, de derechos humanos o que promueva intereses de cualquier partido político o que garanticen los derechos y garantías de partidos políticos de oposición, así como los datos relativos a la salud, a la vida sexual, los datos biométricos, datos materiales y la historia clínica, los cuales solo se recolectarán, incorporarán y/o almacenarán con autorización previa del titular de la información, y cuando sea necesaria para la ejecución de la relación contractual con el titular, siempre y cuando la ley permita acceder a dicha información. Por tanto, el acceso, circulación y tratamiento de los datos sensibles será restringido y limitado a la autorización del titular y a lo estipulado en la normativa vigente.

Tratamiento: Cualquier operación o conjunto de operaciones sobre datos personales, tales como la recolección, almacenamiento, uso, circulación o supresión.

Responsable del tratamiento: Persona natural o jurídica, pública o privada, que por sí misma o en asocio con otros, decida sobre la base de datos y/o el tratamiento de los datos.

Titular: Persona natural cuyos datos personales sean objeto de tratamiento.

Base de datos: Conjunto organizado de datos personales que sea objeto de tratamiento.

Anonimización: Es el proceso por el cual la información de identificación personal se modifica de forma irreversible de tal manera que el responsable del tratamiento, o cualquier tercero, no puede identificar, directa o indirectamente, a la persona asociada a dicha información de identificación personal.

CLÁUSULAS

CLÁUSULA PRIMERA. - MANEJO DE LA INFORMACIÓN CONFIDENCIAL: EL RECEPTOR

reconoce de manera expresa, la naturaleza confidencial de toda la Información que le suministre **LA FUNDACIÓN** y el hecho de que es de su propiedad exclusiva. En consecuencia, **EL RECEPTOR** acepta y está de acuerdo en que:

- 1.) Sólo utilizará la Información Confidencial con el propósito exclusivo de cumplir con las finalidades acordadas, específicamente las relacionadas con el objeto del contrato.
- 2.) No permitirá el acceso a la Información Confidencial ni divulgará de manera parcial o total su contenido a ningún tercero, en especial del sector de la Salud, sin el consentimiento escrito previo de **LA FUNDACIÓN**.

CLÁUSULA SEGUNDA. - INFORMACION NO SUJETA CONFIDENCIALIDAD O RESERVA:

Se excluye de los efectos de este Convenio aquella información no sujeta a confidencialidad y reserva que:

- 1.) Al momento de ser revelada sea ya de dominio público, o que, luego de dicha revelación, se convierta de dominio público por causas no imputables a **EL RECEPTOR**, para lo cual, se entenderá que es de dominio público la información que aparezca en una fuente de divulgación de libre acceso al público en general.
- 2.) Cuando su publicidad sea requerida de acuerdo con las leyes vigentes o por virtud de orden escrita de autoridad competente, evento en el cual **EL RECEPTOR** comunicará inmediatamente por escrito de esta situación a **LA FUNDACIÓN** para que ésta pueda tomar las medidas necesarias para oponerse a dicha petición adelantando las acciones judiciales o administrativas que sean del caso, colaborando con ésta en todo aquello que esté a su alcance para proteger y mantener la reserva de dicha Información Confidencial.
- 3.) Al momento en que **LA FUNDACIÓN** autorice expresamente a divulgar la información por un medio escrito a **EL RECEPTOR**.

CLÁUSULA TERCERA. - OBLIGACIONES DE EL RECEPTOR: EL RECEPTOR encargado

de la Información Confidencial se obliga a dar cumplimiento a la política de seguridad de la información de **LA FUNDACION**, y a mantener estricta confidencialidad sobre la documentación e información que conozca, produzca, reciba, o intercambie con ocasión al objeto del contrato o lo que llegará a conocer en virtud del mismo.

1. Proteger la confidencialidad de la información verbal, escrita o que por cualquier otro medio reciba de **LA FUNDACIÓN** restringiendo su uso exclusivamente a sus Representantes que tengan absoluta necesidad de conocerla y en beneficio de las negociaciones.
2. Usar toda la Información Confidencial que le entregue **LA FUNDACIÓN** o un tercero como parte del desarrollo de El Proyecto que pretende adelantar solamente para efectos anotados en el presente documento o para cumplir con las obligaciones que se pacten en virtud de la relación comercial. Igualmente, se obliga a mantener dicha información en reserva hasta tanto adquiera carácter público.
3. Garantizar que las personas que tengan acceso a la Información Confidencial reconozcan su carácter confidencial. En consecuencia, se obliga a seguir las políticas y pautas establecidas por la institución en cabeza de la Subdirección de Informática para el debido manejo de la información
4. En caso de existir duda en cuanto si alguna información es un secreto comercial o información Confidencial o sensible y esta se encuentra sujeta a los términos del

presente acuerdo de voluntades, deberá de ser tratada como confidencial y, por ende, estará sujeta a los términos de este convenio.

5. Proteger estrictamente la Información Confidencial o sensible que reciba de **LA FUNDACIÓN**, acatando las medidas de seguridad establecidas por la Subdirección de Informática para evitar su divulgación, pérdida, adulteración, uso fraudulento o no adecuado, o cualquier otro incumplimiento a sus obligaciones generales o específicas en el marco del presente contrato.
6. Reportar a la FUNDACIÓN al equipo de ciberseguridad al correo ciberseguridad@fvl.org.co y al área de Protección de Datos personales al correo: datospersonales@fvl.org.co los incidentes de seguridad informática y de la información que se presenten con la Información (física y digital) y/o los equipos tecnológicos inmediatamente después de que se identifique la ocurrencia del incidente.
7. Se obliga a no recolectar **datos personales ni sensibles** adicionales con base a la **Información Confidencial** a la que tenga acceso, y a no realizar cruces de información que permitan adicionar los datos transferidos, ni a enajenar o negociar a título alguno la información.

CLÁUSULA CUARTA. DURACIÓN: El presente Convenio de Confidencialidad estará vigente de manera indefinida, motivo por el cual, **EL RECEPTOR** no podrá divulgar la Información Confidencial en ningún tiempo.

CLÁUSULA QUINTA. - DEVOLUCION DE LA INFORMACION: En caso de terminación del contrato por cualquier causa o terminación del objeto del contrato, **EL RECEPTOR** se obliga, a reintegrar o destruir, según le solicite **LA FUNDACIÓN** por cualquier medio, toda la documentación e información que le haya sido suministrada y todo otro material o documento que incorpore o refleje Información Confidencial, a la que haya tenido acceso y que conserve **EL RECEPTOR**. La entrega de la documentación se deberá efectuar en un plazo no mayor a Cinco (5) días calendarios siguientes a la solicitud de entrega de tal documentación por parte de **LA FUNDACIÓN**. Igualmente, cualquier Información Confidencial mantenida en computadoras, medios magnéticos o cualquier otro similar, será destruida si así es requerido por **LA FUNDACIÓN**. Una vez devuelta y destruida la mencionada documentación, **EL RECEPTOR** hará constar mediante comunicación escrita que no se encuentra en su poder ningún otro documento sujeto a la obligación de confidencialidad aquí establecida.

CLÁUSULA SEXTA. CLÁUSULA PENAL: EL RECEPTOR se compromete a resarcir todos los perjuicios o daños que, con ocasión al objeto del contrato, llegará a ocasionar como consecuencia del incumplimiento de este Convenio de Confidencialidad y de las demás obligaciones anteriormente descritas.

PARAGRAFO: No obstante, lo anterior, **EL RECEPTOR** acepta y reconoce que el pago de la pena aquí pactada no será suficiente para cubrir los perjuicios que resulten de la violación del presente Acuerdo por parte suya. En consecuencia, **LA FUNDACIÓN** podrá perseguir la indemnización de perjuicios y ejercer cualquier medio legal para evitar que se sigan ocasionando perjuicios como consecuencia de la violación.

CLÁUSULA SEPTIMA. PROPIEDAD DE LA INFORMACIÓN: LAS PARTES acuerdan que en

virtud del presente contrato no se transfiere la propiedad de ninguna Información **en especial de la Confidencial, ni de la Sensible**, ni de la que se encuentra en la **Base de Datos de LA FUNDACION a EL RECEPTOR**; perpetuamente continuarán siendo de los **Titulares** y de **LA FUNDACIÓN** respectivamente.

CLÁUSULA OCTAVA. NO RENUNCIA A DERECHOS: La falta o demora de **LA FUNDACIÓN** en ejercer cualquiera de las facultades o derechos consagrados en el presente Convenio de Confidencialidad, o a exigir su cumplimiento, no se interpretará como una renuncia a dichos derechos o facultades ni afectará la validez, total o parcial del Convenio, ni el derecho de ejercer posteriormente tales facultades o derechos, salvo disposición legal o contractual en contrario.

CLAUSULA NOVENA. NO CESION DEL CONVENIO: EL RECEPTOR no podrá ceder el presente Convenio.

CLAUSULA DÉCIMA. TRANSMISIÓN Y/O TRANSFERENCIA DE DATOS PERSONALES Y/O SENSIBLES: EL RECEPTOR no podrá transferir ni transmitir ningún tipo de dato e información hacia partes interesadas externas que no estén aprobadas por **LA FUNDACION** o que no hagan parte esencial de este contrato y su cláusula de confidencialidad, así como el cumplimiento a la normatividad legal vigente en materia de transmisión y transferencia internacional de datos personales. En caso de requerirse esta actividad, se deberá utilizar canales seguros y cifrados salvaguardando la confidencialidad e integridad de la información. No se podrán utilizar medios de comunicación No autorizados por **LA FUNDACIÓN** como herramientas como W-transfer, Google Drive, DropBox, WhatsApp, redes sociales, entre otras.

CLAUSULA UNDÉCIMA SEGURIDAD DE LA INFORMACIÓN Y PROTECCIÓN DE DATOS PERSONALES Y SENSIBLES:

- a) Datos Personales: De acuerdo con lo dispuesto en la Ley 1581/2012, de Protección de Datos Personales, ambas partes se obligan a garantizar, el cumplimiento de esta Ley y de su Reglamento por el Decreto 1377/2013, así como la política de privacidad de datos de la Fundación valle del Lili (AN-FVL-071) garantizando que los datos personales a los cuales se podrá tener acceso en la relación contractual estarán salvaguardados y no podrán ser copiados, modificados, ni eliminados, ni divulgados sin autorización del titular, tampoco usados para fines diferentes a lo autorizado en esta relación contractual
- b) Seguridad de la información: **EL RECEPTOR** se compromete a cumplir con las políticas de seguridad de la información establecidas por **LA FUNDACIÓN**, así mismo a salvaguardar toda información relacionada con El Proyecto que pretende adelantar; además de ello se compromete a:
 - No realizar ninguna copia o distribución de información sensible o confidencial que pueda llegar a obtener durante la ejecución de este contrato, sin previa autorización de **LA FUNDACIÓN**.
 - Usar adecuadamente los equipos tecnológicos así como las herramientas corporativas que **LA FUNDACIÓN** le pueda otorgar para el ejercicio de la relación comercial para con **LA FUNDACIÓN**.

- No utilizar dispositivos de almacenamiento externos, con la finalidad de transportar, almacenar y/o compartir información sensible o confidencial de **LA FUNDACIÓN**, salvo autorización de jefe inmediato y revisado por el área de ciberseguridad de **LA FUNDACIÓN**.
- A no realizar ningún tipo de alteración y modificación al hardware y software de los equipos tecnológicos que pertenezcan a **LA FUNDACIÓN**.
- Adoptar las medidas de seguridad de la información que garanticen la confidencialidad y no divulgación de la información sensible o confidencial entregada por parte de **LA FUNDACIÓN** o que se pueda generar en la relación contractual entre **EL RECEPTOR** y **LA FUNDACIÓN**, teniendo presente mantener un alto nivel de cuidado, para evitar su pérdida, robo o sustracción o divulgación no autorizada.
- En sitios externos a alguna de las sedes de **LA FUNDACIÓN** presentes y futuras, no utilizar redes WIFI o LAN (cable) gratuitas y/o públicas que puedan afectar la Confidencialidad, Integridad y Disponibilidad de la información.
- Utilizar las herramientas de seguridad y protocolos de cifrado de información definidos por **LA FUNDACIÓN** para la transferencia de todo tipo de información, y usar solo aplicaciones corporativas para tal fin según nuestra política de USO ACEPTABLE DE LA TECNOLOGÍA INFORMÁTICA AN-INF-003.
- Abstenerse del uso de herramientas que no sean institucionales (WhatsApp, Line, Google Drive, Dropbox, entre otras) que comprometan la Confidencialidad, Privacidad e Integridad de la Información.
- Cumplir a cabalidad cualquier lineamiento y política de seguridad de la información que **LA FUNDACIÓN** crea pertinente implementar para salvaguardar la Confidencialidad, Integridad, Disponibilidad de la información.
- Destruir cualquier copia de información no autorizada por **LA FUNDACION**, al terminar la relación contractual.
- Las demás previstas por la Ley Colombiana

A continuación, **EL RECEPTOR** manifiesta que ha leído y estudiado de manera detenida los términos y el contenido de este Convenio de Confidencialidad, al igual que acepta todas sus condiciones y firma electrónicamente como constancia del acuerdo.

EL RECEPTOR



Hernan Darío Vargas Cardona
C.C 1097721437 de Montenegro
Fecha: 28/06/2024

Bibliografía

- [1] F. M. Salud, “Inteligencia artificial en el campo de la salud,” *Colección de Biotica*, vol. 26, 2023.
- [2] S. del Campo-Estepar, E. Santos-Armentia, J. Lorenzo-González, M. Novoa-Ferro, and R. Alemán-Millares, “Valoración del ASPECTS automatizado como herramienta de inteligencia artificial en la práctica clínica diaria,” *Rev Neurol.*, vol. 74, no. 01, pp. 1–7, 2022.
- [3] J. J. Carballo Pacheco, “Clasificación de imágenes médicas con técnicas de deep learning,” 2022.
- [4] A. Ebrahimi, S. Luo, and R. Chiong, “Introducing transfer learning to 3d resnet-18 for alzheimer’s disease detection on mri images,” in *2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ)*, 2020, pp. 1–6.
- [5] S. Sannasi Chakravarthy, N. Bharanidharan, C. Vinothini, and et al., “Activación adaptativa de mish y modelo sea-resnet50 basado en optimizador de ranger con ia explicable para la clasificación multiclase de imágenes de rayos x de tórax de covid-19,” *BMC Medical Imaging*, vol. 24, no. 206, 2024.
- [6] A. Kumar. (2022) Support vector machine (svm) python example. Accedido: 23 de octubre de 2024. [Online]. Available: <https://vitalflux.com/classification-model-svm-classifier-python-example/>
- [7] Premanand. (2023) The a-z guide to support vector machine. Accedido: 23 de octubre de 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/06/support-vector-machine-better-understanding/>
- [8] Tavish. (2024) Guide to k-nearest neighbors algorithm in machine learning. Accedido: 23 de octubre de 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/>
- [9] L. Torres. (20-12-2020) Curva roc y auc en python, the machine learners. [Online]. Available: <https://www.themachinelearners.com/curva-roc-vs-prec-recall/>
- [10] P. Arvindpdmn. (20-8-2019) Confusion matrix, devopedia. [Online]. Available: <https://devopedia.org/confusion-matrix>
- [11] R. Mikuliky and N. Wahlgren, “Treatment of acute stroke: an update,” *J. Intern. Med*, vol. 278, no. 2, p. 145–165, 2015.
- [12] S. G. Pigretti, M. J. Alet, C. E. Mamani, C. Alonzo, M. Aguilar, and H. J. Álvarez, “Consenso sobre accidente cerebrovascular isquémico agudo.” *Medicina (B. Aires)*, vol. vol.79, no. 2, pp. 1–46, 2019. [Online]. Available: https://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S0025-76802019000400001

- [13] N. do Conhecimento. (2024) Accidente vascular cerebral (avc): aspectos generales. [Online]. Available: https://www.nucleodoconhecimento.com.br/salud/accidente-vascular-cerebral#google_vignette
- [14] M. de Salud y Protección Social. (20-06-2021) Enfermedad cerebrovascular, otra comorbilidad priorizada contra el covid-19. [Online]. Available: <https://www.minsalud.gov.co/Paginas/Enfermedad-cerebrovascular,-otra-comorbilidad-priorizada-contra-el-covid-19.aspx>
- [15] E. Boyacá. (27-10-2022) Continúa la lucha por el accidente cerebrovascular (acv) en colombia”, periódico el diario. [Online]. Available: <https://periodicoeldiario.com/continua-la-lucha-por-el-accidente-cerebrovascular-acv-en-colombia/>
- [16] I. C. Puentes Madera, “Epidemiología de las enfermedades cerebrovasculares de origen extracranial,” *Revista Cubana de Angiología y Cirugía Vascular*, vol. 15, no. 2, pp. 66–74, 2014.
- [17] N. Tajbakhsh, J. Y. Shin, S. R. Gurudu, R. T. Hurst, C. B. Kendall, M. B. Gotway, and J. Liang, “Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?” *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1299–1312, 2016.
- [18] V. Gulshan, L. Peng, M. Coram, and et al, “Accuracy of a Deep Learning Algorithm for Detection of Diabetic Retinopathy,” *JAMA*, vol. 316, no. 22, pp. 2402–2410, 2016.
- [19] R. Figueroa Casanova and H. M. Patiño Rodríguez, “Experiencia en el manejo del ataque cerebrovascular isquémico en dos centros de tercer nivel de la ciudad de Ibagué (Colombia) entre junio del 2019 y junio del 2020,” *Acta Neurológica Colombiana*, vol. 38, no. 1, 2022.
- [20] D. Smajlović, “Strokes in young adults: epidemiology and prevention,” *Vasc Health Risk Manag*, vol. 11, pp. 157–64, 2015.
- [21] M. S. Ekker, E. M. Boot, A. B. Singhal, K. S. Tan, S. Dobbie, A. M. Tuladhar, and F. E. Leeuw, “Epidemiology, aetiology, and management of ischaemic stroke in young adults,” *Lancet Neurol*, vol. 17, no. 9, p. 790–801, 2018.
- [22] J. M. Ocampo Chaparro, C. A. César Augusto, J. E. Álvarez Payares, and J. P. Muñoz Lombo, “Neurosífilis meningovascular como causa de accidente cerebrovascular en paciente joven: reporte de caso,” *Rev. médicas*, vol. 32, no. 2, p. 53–58, 2019.
- [23] H. P. Adams Jr, B. H. Bendixen, L. J. Kappelle, J. Biller, B. B. Love, D. L. Gordon, and E. E. Marsh 3rd, “Classification of subtype of acute ischemic stroke. Definitions for use in a multicenter clinical trial. TOAST. Trial of Org 10172 in Acute Stroke Treatment.” *Stroke*, vol. 24, no. 1, p. 35–41, 1993.
- [24] R. Brown and MayoClinic.org. (08-07-2023) Accidente cerebrovascular. [Online]. Available: <https://www.mayoclinic.org/es/diseases-conditions/stroke/symptoms-causes/syc-20350113>

- [25] M. G. Bandyk, D. R. Gopireddy, C. Lall, K. C. Balaji, and J. Dolz, “MRI and CT bladder segmentation from classical to deep learning based approaches: Current limitations and lessons,” *Comput. Biol. Med.*, vol. 134, no. 104472, p. 104472, 2021.
- [26] K. Drukker, P. Yan, A. Sibley, and G. Wang, “Chapter 4 - Biomedical imaging and analysis through deep learning,” *Artificial Intelligence in Medicine, L. Xing, M. L. Giger, y J. K. Min, Eds. San Diego, CA, Estados Unidos de América: Elsevier*, pp. 49–74, 2021.
- [27] A. Soto, G. Morales, G. Echeverría, M. B. Colinas, P. Canales, and D. Contreras, “Factores asociados a llegada y evaluación precoz de pacientes con ataque cerebrovascular en un hospital regional de alta complejidad,” *Rev. chil. neuro-psiquiatr.*, vol. 57, no. 2, 2019.
- [28] H. P. Adams Jr, P. H. Davis, E. C. Leira, K. C. Chang, B. H. Bendixen, W. R. Clarke, R. F. Woolson, and M. D. Hansen, “Baseline NIH Stroke Scale score strongly predicts outcome after stroke: A report of the Trial of Org 10172 in Acute Stroke Treatment (TOAST),” *Neurology*, vol. 53, no. 1, pp. 126–31, 1999.
- [29] N. Tenerife. (27-12-2021) Cómo saber si alguien está sufriendo un ictus y cómo actuar. escala cincinnati o método f.a.s.t. [Online]. Available: <https://neuro-centro.com/como-saber-si-alguien-esta-sufriendo-un-ictus-y-como-actuar-escala-cincinnati-o-metodo-f-a-s-t/>
- [30] [Online]. Available: <https://www.linkedin.com/in/oscarecheverry>
- [31] D. Kotovich, G. Twig, Z. Itsekson-Hayosh, M. Klug, A. Ben Simon, G. Yaniv, E. Konen, N. Tau, D. Raskin, P. J. C. Chang, and D. Orion, “The impact on clinical outcomes after 1 year of implementation of an artificial intelligence solution for the detection of intracranial hemorrhage,” *International Journal of Emergency Medicine*, vol. 16, no. 50, 2023.
- [32] Medlineplus. (2022) Accidente cerebrovascular. [Online]. Available: <https://medlineplus.gov/spanish/stroke.html>
- [33] C. Alfonso García, A. Reyes Martínez, V. García, A. Ricaurte Fajardo, I. Torres, and J. Corral, “Actualización en diagnóstico y tratamiento del ataque cerebrovascular isquémico agudo,” vol. 60, no. 3, 2019.
- [34] A. neurológica colombiana. (2022) Accidente cerebrovascular. [Online]. Available: <https://medlineplus.gov/spanish/stroke.html>
- [35] T. H. Institute. (2023) Tipos de accidentes cerebrovasculares. [Online]. Available: <https://www.texasheart.org/heart-health/heart-information-center/topics/tipos-de-accidente-s-cerebrovasculares/>
- [36] N. Rubio Rojas and J. A. Miranda Quintana, “Diagnóstico precoz de las enfermedades cerebrovasculares isquémicas,” *Medisan*, vol. 17, no. 11, p. 8089–9003, 2013.

- [37] O. M. Salud. (2005) Estrategia paso a paso de la oms para la vigilancia de accidentes cerebrovasculares. [Online]. Available: <https://www3.paho.org/spanish/ad/dpc/nc/steps-stroke.pdf>
- [38] H. C. Branco Rodrigues, F. Torres Pacheco, and A. J. Rocha, “Collateral blood vessels in acute ischemic stroke: a physiological window to predict future outcomes,” *Arq. Neuro-Psiquiatr.*, vol. 74, no. 8, p. 662–670, 2016.
- [39] I. Sosa Testé and J. D. García Salman. Neuroprotección en la isquemia cerebral. experiencias con la eritropoyetina humana recombinante. [Online]. Available: <https://revecuatneurol.com/wp-content/uploads/2015/06/Neuroproteccion.pdf>
- [40] medlineplus. (2023) Tomografía computarizada. [Online]. Available: <https://medlineplus.gov/spanish/ctscans.html>
- [41] Iberdrola. (2023) Descubre los principales beneficios del machine learning. [Online]. Available: <https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico>
- [42] F. Ramirez. (2023) Que son las inteligencia artificial y el machine learning. [Online]. Available: <https://itsoftware.com.co/content/que-son-la-inteligencia-artificial-y-el-machine-learning/>
- [43] E. Toprak and Kaya Kalkan, “Comparación del rendimiento de la regresión múltiple y la red neuronal artificial en la determinación del orden de importancia de los predictores en la investigación educativa,” *Revista de educación*, no. 399, p. 233–268, 2023.
- [44] A. Delgado, *Inteligencia artificial y minirobots*. Bogotá: ECOE Ediciones, 1998.
- [45] J. B. (29-11-2018) ¿cómo funcionan las convolutional neural networks? visión por ordenador”, aprende machine learning. [Online]. Available: <https://www.aprendemachinelearning.com/cómo-funcionan-las-convolutional-neural-networks-vision-por-ordenador/>
- [46] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” 2015. [Online]. Available: <https://arxiv.org/abs/1512.03385>
- [47] R. Cui and M. Liu, “Hippocampus analysis by combination of 3-d densenet and shapes for alzheimer’s disease diagnosis,” *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 5, pp. 2099–2107, 2019.
- [48] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2261–2269.
- [49] S. Ioffe, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *arXiv preprint arXiv:1502.03167*, 2015.

- [50] H. Mzoughi, I. Njeh, A. Wali, M. Slima, A. BenHamida, C. Mhiri, and K. Mahfoudhe, “Deep multi-scale 3d convolutional neural network (cnn) for mri gliomas brain tumor classification,” *Journal of Digital Imaging*, vol. 33, no. 4, pp. 903–915, Aug 2020.
- [51] M. Arbabshirani, B. Fornwalt, G. Mongelluzzo, and et al., “Advanced machine learning in action: identification of intracranial hemorrhage on computed tomography scans of the head with clinical workflow integration,” *npj Digital Medicine*, vol. 1, p. 9, 2018.
- [52] Interactive Chaos. (2022) Linear kernel. Accedido: 23 de octubre de 2024. [Online]. Available: <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/linear-kernel-0>
- [53] GeeksforGeeks. (2024) Radial basis function kernel – machine learning. Accedido: 23 de octubre de 2024. [Online]. Available: <https://www.geeksforgeeks.org/radial-basis-function-kernel-machine-learning/>
- [54] V. D. Kuhn Max. (2024) Polynomial support vector machines. Accedido: 23 de octubre de 2024. [Online]. Available: https://parsnip.tidymodels.org/reference/svm_poly.html
- [55] G. Sánchez-Díaz, U. E. Escobar-Franco, L. R. Morales-Manilla, I. Piza-Dávila, C. Aguirre-Salado, and A. Franco-Arcega, “Un algoritmo de clasificación incremental basado en los k vecinos más similares para datos mezclados,” *Revista Facultad de Ingeniería Universidad de Antioquia*, no. 67, pp. 19–30, jun 2013, accedido el 03 de noviembre de 2024. [Online]. Available: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-62302013000200002&lng=en&nrm=iso
- [56] Amazon Web Services, “Algoritmo k vecinos más próximos (k-nn),” 2024, accedido el 03 de noviembre de 2024. [Online]. Available: https://docs.aws.amazon.com/es_es/sagemaker/latest/dg/k-nearest-neighbors.html
- [57] K. Y. Chan and K. Muhammad, “Deep neural networks in the cloud: Review, applications, challenges and research directions,” *Neurocomputing*, 2023, accessed: 2024-11-03. [Online]. Available: <https://www.sciencedirect.com/topics/computer-science/multilayer-perceptron>
- [58] Gamco. (2021) ¿qué es el perceptron multicapa? Accedido: 24 de octubre de 2024. [Online]. Available: <https://gamco.es/glosario/perceptron-multicapa-mlp/>
- [59] T. Chen and C. Guestrin, “Xgboost: A scalable tree boosting system,” in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.
- [60] J. H. Friedman, “Greedy function approximation: a gradient boosting machine,” *Annals of statistics*, pp. 1189–1232, 2001.
- [61] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin, “Catboost: unbiased boosting with categorical features,” *Advances in neural information processing systems*, vol. 31, 2018.

- [62] J. B. M. Vega. (2020) Tutorial: Xgboost en python. Accedido: 24 de octubre de 2024. [Online]. Available: <https://medium.com/@jboscomendoza/tutorial-xgboost-en-python-53e48fc58f73>
- [63] R. Díaz. (08-5-2020) The machine learners, métricas de clasificación. [Online]. Available: <https://www.themachinlearners.com/metricas-de-clasificacion/>
- [64] D. Müller, I. Soto Rey, and F. Kramer, “Towards a guideline for evaluation metrics in medical image segmentation,” *BMC Res Notes.*, vol. 15, no. 210, 2022.
- [65] profesorDATA. (07-8-2020) Evaluando los modelos de clasificación en aprendizaje automático: La matriz de confusión. [Online]. Available: <https://www.themachinlearners.com/metricas-de-clasificacion/>
- [66] M. Sanjay Sirsat, E. Fermé, and J. Cámara, “Machine Learning for Brain Stroke: A Review,” *Journal of Stroke and Cerebrovascular Diseases*, vol. 29, no. 10, p. 105162, 2020.
- [67] V. Bandi, D. Bhattacharyya, and D. Midhunchakkravarthy, “Prediction of Brain Stroke Severity Using Machine Learning,” *Revue d’Intelligence Artificielle*, vol. 34, no. 6, pp. 753–761, 2020.
- [68] B. Akter, A. Rajbongshi, S. Sazzad, R. Shakil, J. Biswas, and U. Sara, “A machine learning approach to detect the brain stroke disease,” *2022 4th International Conference on Smart Systems and Inventive Technology (ICSSIT)*, pp. 897–901, 2022.
- [69] M. Nishio, S. Koyasu, S. Noguchi, T. Kiguchi, K. Nakatsu, T. Akasaka, H. Yamada, and K. Itoh, “Automatic detection of acute ischemic stroke using non-contrast computed tomography and two-stage deep learning model,” vol. 196, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0169260720315443>
- [70] K.-Y. Lee, C.-C. Liu, D. Yen-Ting Chen, C.-L. Weng, H.-W. Chiu, and C.-H. Chiang, “Automatic detection and vascular territory classification of hyperacute staged ischemic stroke on diffusion weighted image using convolutional neural networks.” vol. 404, 2023. [Online]. Available: <https://doi.org/10.1038/s41598-023-27621-4>
- [71] C.-L. Chin, B.-J. Lin, G.-R. Wu, T.-C. Weng, C.-S. Yang, R.-C. Su, and Y.-J. Pan, “An automated early ischemic stroke detection system using cnn deep learning algorithm,” pp. 368–372, 2017.
- [72] T. S. D. Community, “3d slicer: A platform for medical image computing,” 2025, accedido: 30 de enero de 2025. [Online]. Available: <https://slicer.org/>
- [73] M. Consortium, “Monai auto3dseg: Automatic 3d segmentation,” 2025, accedido: 30 de enero de 2025. [Online]. Available: <https://docs.monai.io/en/stable/auto3dseg.html>
- [74] Keras Team. (2023) Bayesian tuner. Accedido: 29 de septiembre de 2024. [Online]. Available: https://keras.io/api/keras_tuner/tuners/bayesian/