



Pontificia Universidad
JAVERIANA
Cali

**SISTEMA DE RECONOCIMIENTO DE LA ESTRUCTURA CEREBRAL CAVUM SEPTUM PELLUCIDUM
BASADO EN DEEP LEARNING PARA EL ANÁLISIS DE ANOMALÍAS DEL DESARROLLO EN
IMÁGENES DE ULTRASONIDO FETAL EN 2D**

Milton Fabián Cifuentes Ortega
Código 8986498

Proyecto Aplicado para optar al título de
Magíster en Ciencia de Datos

Director(a)
Cristian Alejandro Torres Valencia

FACULTAD DE INGENIERÍA Y CIENCIAS
MAESTRÍA EN CIENCIA DE DATOS
SANTIAGO DE CALI, 20 DE ENERO DE 2025

TABLA DE CONTENIDO

Contenido

I.	LISTA DE FIGURAS	V
II.	LISTA DE TABLAS	VII
III.	LISTA DE ANEXOS	VIII
1	DEFINICIÓN DEL PROBLEMA	2
1.1	PLANTEAMIENTO DEL PROBLEMA	2
1.2	FORMULACIÓN DEL PROBLEMA	5
2	OBJETIVOS DEL PROYECTO	7
2.1	OBJETIVO GENERAL	7
2.2	OBJETIVOS ESPECÍFICOS	7
3	MARCO TEÓRICO Y ANTECEDENTES	8
3.1	MARCO TEÓRICO	8
3.2	ANTECEDENTES	17
3.2.1.	Antecedentes del Proyecto	17
3.2.2.	Antecedentes para la determinación de la anormalidad de la estructura Cavum Septum Pellucidum	23
4	DESARROLLO DE MODELOS PARA LA IDENTIFICACION DEL PLANO CRANEAL Y ESTRUCTURA CAVUM SEPTUM PELLUCIDUM	28
4.1	Entendimiento de la necesidad y motivaciones medicas del proyecto	29
4.2	Selección de Datos para análisis	29
4.3	Análisis de la información	30
4.4	Pre-procesamiento de Datos	30

4.5	Diseño de modelo	31
4.6	Ajustes al Modelo	32
4.7	Implementación de modelo final	33
5	SELECCIÓN DE CRITERIOS DE RECOLECCIÓN Y PROCESAMIENTO DE LAS IMÁGENES DE ULTRASONIDO FETAL EN 2D.	34
5.1	Identificar y Establecer las características adecuadas para las imágenes	34
5.2	Búsqueda de bases de datos de imágenes de ultrasonido	34
5.2.1	búsqueda de bases de datos de imágenes	34
5.2.2	búsqueda de bases de datos usadas en otros trabajos de investigación	35
5.3	Selección del conjunto de imágenes o base de datos	35
5.4	Resumen de las actividades	36
6	IMPLEMENTACIÓN DE MODELOS DE APRENDIZAJE DE MÁQUINA PARA LA IDENTIFICACIÓN AUTOMÁTICA DEL PLANO CEREBRAL Y EL RECONOCIMIENTO DEL CAVUM SEPTUM PELLUCIDUM	38
6.1	Revisión del estado del arte	38
6.2	Construcción del conjunto de Datos	38
6.2.1	Análisis Exploratorio de la información	38
6.2.2	Pre-procesamiento y Selección de la información.....	42
6.2.3	Construcción de carpetas con el conjunto de datos.....	44
6.3	Definición e implementación de modelo de aprendizaje supervisado	45
6.4	Tareas de Validación y Ajuste del modelo seleccionado	51
6.5	Modelo para determinar regiones y la estructura Cavum Septum Pellucidum en las imágenes de ultrasonido	54
6.5.1	Etiquetado de Mascaras.....	55
6.5.2	Análisis del Dataset	57
6.5.3	Pre-procesamiento del dataset.....	59

6.5.3.1. Selección de imágenes con Json valido.....	59
6.5.4 Diseño, mejoramiento, validación e implementación de U-net planos craneales	63
6.6 Resumen de las Actividades	81
7 MÉTRICAS DE EVALUACIÓN DE LA ESTRUCTURA CSP EN TÉRMINOS DE NORMALIDAD O ANORMALIDAD.....	83
7.1. Definición y Generación de métricas	83
7.2. Resumen de actividades.....	87
8 CONCLUSIONES Y TRABAJOS FUTUROS	88
8.1 CONCLUSIONES	88
8.2 TRABAJOS FUTUROS	89
9 REFERENCIAS BIBLIOGRÁFICAS	90

I. LISTA DE FIGURAS

Figura 1 - Evolución del Ultrasonido	10
Figura 2 - Transductor para ultrasonidos	12
Figura 3 - Ubicación del Cavum Septum Pellucidum.....	13
Figura 4 - Interacción de pasos en un sistema de procesamiento de imágenes	15
Figura 5 - Componentes de solución.....	23
Figura 6 - Flujo de Proceso Desarrollo de Modelo	29
Figura 7 - Diagrama de Barras Plano Cerebral	30
Figura 8 - Imágenes de muestra Ultrasonido	39
Figura 9 - Dataset	39
Figura 10 - Diagrama de barras Distribución de planos cerebrales	40
Figura 11 - Ultrasonido Craneal.....	41
Figura 12 - Diagrama de Barras Trans-Thalamic	41
Figura 13 - Diagrama de Barras Trans-Cerebellum	41
Figura 14 - Diagrama de Barras Trans-Ventricular	42
Figura 15 - Ultrasonido Craneal.....	43
Figura 16 - Diagrama de Barras Balanceo de Oversampling	43
Figura 17 - Imágenes de Ultrasonidos artificiales	44
Figura 18 - Distribución de carpetas	44
Figura 19 - Matriz De Confusión Modelo Resnet50	47
Figura 20 - Graficas de entrenamiento y validación Modelo Resnet 50.....	47
Figura 21 - Matriz de Confusión Modelo Resnet 101	48
Figura 22 - Graficas de entrenamiento y validación Modelo Resnet 101.....	48
Figura 23 - Matriz de confusión Modelo VGG16.....	49
Figura 24 - Graficas de entrenamiento y validación Modelo VGG16.....	49
Figura 25 - Matriz de confusión Modelo VGG19.....	50
Figura 26 - Graficas de entrenamiento y validación Modelo VGG19.....	50
Figura 27 - Grafica de Comportamiento de Todos Los Modelos (Resnet50, Resnet101, VGG16 y VGG19)	51
Figura 28 - Matriz de confusión Segunda Ejecución	52
Figura 29- Graficas de entrenamiento y validación Segunda Ejecución	52
Figura 30 - Valores de rendimiento.....	52
Figura 31 - Matriz de confusión Modelo VGG19 Mejorado.....	53
Figura 32 - Graficas de entrenamiento y validación Modelo VGG19 Mejorado.....	54
Figura 33 - Valores de rendimiento.....	54
Figura 34 - Comparación de imágenes por Rango de Similitud	56
Figura 35 - Distribución de Etiquetas por autor	56
Figura 36 - Distribución de Imágenes por Json Valido por plano craneal.....	57
Figura 37 - Imágenes de planos craneales con etiqueta.....	58
Figura 38 - Distribución de registros con Oversampling	60

Figura 39 - Proceso de Limpieza Json	61
Figura 40 - Ejemplo redimensionamiento	62
Figura 41 - Distribución de Carpetas	63
Figura 42 - Curva de Perdida Modelo Trans-Thalamic	65
Figura 43 - Curva de Accuracy Modelo Trans-Thalamic	65
Figura 44 - Curva ROC Modelo Trans-Thalamic	66
Figura 45 - Curva Precision-Recall Modelo Trans-Thalamic	66
Figura 46 - Muestra de Mascara Predicha	66
Figura 47 - Curva de Perdida modelo Trans-Thalamic Mejorado	68
Figura 48 - Curva de Accuracy modelo Trans-Thalamic Mejorado	68
Figura 49 - Curva ROC modelo Trans-Thalamic Mejorado	68
Figura 50 - Curva Precision Recall del modelo Trans-Thalamic mejorado	69
Figura 51 - Muestra de mascara Predicha con Modelo Trans-Thalamic Mejorado	69
Figura 52 - Curva de Perdida Modelo Básico Trans-Ventricular	70
Figura 53 - Curva de Accuracy Modelo Básico Trans-Ventricular	71
Figura 54 - Curva ROC del Modelo Básico Trans-Ventricular	71
Figura 55 - Curva de Precision-Recall del Modelo Básico Trans-Ventricular	71
Figura 56 - Muestra de mascara predicha por el modelo Básico Trans-Ventricular	72
Figura 57 - Curva de Perdida del modelo Trans-Ventricular Mejorado	73
Figura 58 - Curva de Accuracy del modelo Trans-Ventricular Mejorado	73
Figura 59 - Curva ROC del modelo Trans-Ventricular Mejorado	74
Figura 60 - Curva Precision-Recall del modelo Trans-Ventricular Mejorado	74
Figura 61 - Muestra de imagen predicha Modelo Mejorado Trans-Ventricular	74
Figura 62 - Curva de Perdida del Modelo Básico Trans-Cerebellum	76
Figura 63 - Curva de Accuracy del Modelo Básico Trans-Cerebellum	76
Figura 64 - Curva ROC del Modelo Básico Trans-Cerebellum	76
Figura 65 - Curva de Precision-Recall del Modelo Básico Trans-Cerebellum	77
Figura 66 - Muestra de mascara Predicha Modelo Básico Trans-Cerebellum	77
Figura 67 - Curva de Perdida del Modelo Trans-Cerebellum Mejorado	78
Figura 68 - Curva de Accuracy del Modelo Trans-Cerebellum Mejorado	79
Figura 69 - Curva ROC del Modelo Trans-Cerebellum Mejorado	79
Figura 70 - Curva de Precision-Recall del Modelo Trans-Cerebellum Mejorado	79
Figura 71 - Muestra de imagen predicha del modelo Trans-Cerebellum Mejorado	80
Figura 72 - Distribución de Carpetas Mascaras Predichas	81
Figura 73 - Mascara Original y Predicha	83
Figura 74 - Mascaras	83
Figura 75 - Imágenes Con Diagnosticas	84
Figura 76 - Distribución de Imágenes por Diagnostico basado en el tamaño	85
Figura 77 - Distribución de Imágenes por Diagnostico basado en la Desviación Estándar	86

II. LISTA DE TABLAS

Tabla 1 - Retos clínicos y técnicos del ultrasonido	4
Tabla 2 - Momentos en la Historia del ultrasonido.....	9
Tabla 3 - Pasos del procesamiento de imágenes	14
Tabla 4 - Antecedentes Deep Learning en Ultrasonido	17
Tabla 5 - Revisión Sistemática Anomalías del Cavum Septum Pellucidum.....	23
Tabla 6 - Ventajas RandomSearch e HyperBand	32
Tabla 7 - Criterios de selección de imágenes	35
Tabla 8 - Resumen de resultados Primer Objetivo	36
Tabla 9 - Distribución de Imágenes por Plano cerebral.....	40
Tabla 10 - Distribución de imágenes por tamaño	41
Tabla 11 - Cantidad de Imágenes para entrenamiento y prueba	45
Tabla 12 - Estadísticas Modelo Resnet 50	47
Tabla 13 - Estadísticas Modelo Resnet 101.....	48
Tabla 14 - Estadísticas Modelo VGG16.....	48
Tabla 15 - Estadísticas Modelo VGG19.....	49
Tabla 16 - Estadísticas Modelo VGG19 - Segunda Ejecución.....	51
Tabla 17 - Parámetros de Mejoramiento VGG19	53
Tabla 18 - Estadísticas Modelo VGG19 mejorado	53
Tabla 19 - Distribución por plano de imágenes que tienen Json Valido.....	59
Tabla 20 - Distribución de registros generados por Oversampling	60
Tabla 21 - Resultados Entrenamiento Modelo Trans-Thalamic.....	65
Tabla 22 - Resultado Mejoramientos con HyperBand	67
Tabla 23 - Resultados Modelo Trans-Thalamic Mejorado	67
Tabla 24 - Resultado Modelo Básico Trans-Ventricular	70
Tabla 25 - Resultado Mejoramientos con RandomSearch	72
Tabla 26 - Resultados Modelo Trans-Ventricular Mejorado.....	73
Tabla 27 - Resultado Modelo Básico Trans-Cerebellum	75
Tabla 28 - Resultado Mejoramientos con RandomSearch	78
Tabla 29 - Resultados Modelo Trans-Cerebellum Mejorado	78
Tabla 30 - Resumen de resultados Segundo Objetivo	81
Tabla 31 - Medidas Por Plano Craneal Calculadas.....	85
Tabla 32 - Resumen de resultados Tercer Objetivo	87

III. LISTA DE ANEXOS

Anexo A - 001 - Proyecto de Grado- Primer Modelo Clasificación de Planos.....	45
Anexo B - 001 - Proyecto de Grado- Primer Modelo Clasificación de Planos.....	54
Anexo C - 002 -Proyecto de Grado- Generación de Conjuntos de Datos para Modelo Identificación Estructura	63
Anexo D - 003-1 - Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans- Thalamic	70
Anexo E - 003-2 - Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans- Ventricular	75
Anexo F - 003-3 - Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans- Cerebellum	80
Anexo G - 004 - Proyecto de Grado- Calculo de Anormalidad o Normalidad.....	86

INTRODUCCIÓN

La medicina es un área que ha iniciado desde los comienzos de la humanidad, esto se puede evidenciar debido a que la primera receta médica data de hace más de 4000 años y fue encontrada en una tablilla en la ciudad de Nippur [1]. La medicina cuenta con muchas ramas cada una encargada de una parte específica del cuerpo humano, ya sea endocrinos, cardiólogos o gastroenterólogos, pero se debe tener un especial interés en la perinatología (vertiente de la obstetricia) debido a que es un área de especial interés gracias a sus aplicaciones en la prevención de enfermedades.

La perinatología juega un papel fundamental en el control y prevención de posibles enfermedades o anomalías dentro del crecimiento y desarrollo del feto, estos procedimientos son llevados a cabo gracias a múltiples procesos entre los cuales existen algunos que realizan un uso importante de las imágenes generadas por ultrasonidos. Esta innovación tecnológica ha tenido un gran impacto dentro del análisis de la evolución neonatal, y desde 1950 hasta la actualidad es considerado como un instrumento de diagnóstico en la medicina [2], además que es uno de los procesos preferidos debido a que no es invasivo, tiene un bajo costo y permite la generación de imágenes en tiempo real [3].

A pesar de las cualidades del ultrasonido, su análisis es un proceso que presenta una serie de inconvenientes que hacen de esta tarea un proceso tedioso y con probabilidades de errores de diagnóstico, lo anterior se presenta debido a temas tanto clínicos como técnicos. Dentro de este tipo de problemas podemos tener: ruido en las imágenes, posición del feto, fisionomía del paciente entre otros [4], los cuales impactan de forma negativa en los resultados del diagnóstico, y afectan la curva de aprendizaje de la disciplina por parte de los especialistas.

Es así como una mala interpretación o la omisión de una anomalía en una imagen de ultrasonido puede llegar a representar un gran problema, esto lo podemos ver reflejado en lo que menciona la Organización mundial de la salud en donde se especifica que los defectos congénitos llegan a representar la muerte de 240.000 recién nacidos [5]. Adicionalmente el 94% de los niños afectados por anomalías o trastornos congénitos graves nacen en países de ingresos medios o bajos donde puede existir problemas de acceso al sector salud [5]. Teniendo en cuenta la importancia del análisis de imágenes de ultrasonido para detección de anomalías y su alto impacto social, vemos una gran oportunidad para la aplicación de metodologías de Machine Learning que permitan la automatización de estos procesos y así brindar un apoyo al personal especializado en la identificación de una anomalía que no sería vista de manera sencilla por los ecógrafos o médicos a cargo.

Lo que se realizó en el proyecto fue la definición, desarrollo e implementación de un sistema de reconocimiento de la estructura cerebral Cavum Septum Pellucidum basado en Deep Learning para el análisis de anomalías del desarrollo en imágenes de ultrasonido fetal en 2D. Este sistema permitió que se automatice la identificación de la anomalía de la estructura y facilitó el proceso de análisis para todos los involucrados. Además, el sistema obtuvo altos rangos de precisión o AUC ROC que le permitirán fortalecer la toma de decisiones en caso de presentarse una anomalía en la estructura. Estas decisiones podrían ser de tipo quirúrgico o sencillamente de tratamiento médico.

1 DEFINICIÓN DEL PROBLEMA

1.1 PLANTEAMIENTO DEL PROBLEMA

Según la organización Panamericana de Salud para el año 2020 alrededor de 8 millones de recién nacidos nacen con un defecto congénito grave, y cerca de 3 millones mueren antes de cumplir los 5 años. Adicionalmente, se puede observar este mismo panorama para América Latina, en donde tenemos que el 21 % de los fallecimientos en menores de 5 años corresponde a defectos congénitos y uno de cada 5 bebés mueren por este mismo tipo de defectos durante los primeros 28 días de vida [6].

Teniendo en cuenta lo anterior una de las formas más comúnmente utilizadas para poder observar o identificar anomalías en el desarrollo de los fetos es la toma de exámenes de la forma de la cabeza y el cerebro durante el periodo fetal [7], para lo cual se generan imágenes mediante procesos de ecografías (Ultrasonidos). Esto debido a que es un método no invasivo y libre de radiación el cual posee un bajo costo y la capacidad de visualización en tiempo real [3].

Es así como uno de los procesos más críticos dentro del análisis de las imágenes de ecografías es la identificación de estructuras craneales para la detección prenatal básica de malformaciones o anomalías [3]. La importancia de la detección de estas estructuras se debe a que las deformidades cerebrales fetales son las más comunes (1 en cada 100 nacimientos) [4].

Pero el análisis de las imágenes para la identificación de estructuras craneales en fetos es un proceso manual y presenta una serie de inconvenientes tales como:

- Aumento del tejido adiposo materno dificulta la identificación en la imagen (obesidad). [4].
- Falta de familiaridad de los médicos con la patología [4].
- Anatomía cerebral complicada [4].
- Poca experiencia del ecografista o la orientación del feto [3] [4].
- La delineación manual de estructuras detalladas requiere conocimientos anatómicos expertos, adicionalmente es una tarea que implica de mucho tiempo y propensa a diagnósticos errados. [8] [9].

Teniendo en cuenta lo anterior se puede determinar que la segmentación o análisis manual requiere de una tarea desafiante [7] para la detección precisa de estructuras, la cual puede conllevar a la omisión (alta variabilidad intra-observador) o mala identificación de anomalías dentro de los dictámenes realizados a imágenes de ecografías craneales fetales [8].

La toma de ultrasonidos fetales afronta desafíos tanto clínicos como técnicos. Dentro de los problemas clínicos se tienen otros inconvenientes tales como: la alta movilidad del feto, postura fetal,

movilidad fetal, la corta longitud del tronco parietal fetal, el oligohidramnios y las discrepancias entre los observadores, lo cual puede conllevar a una dificultad bastante grande al momento de realizar el procedimiento de toma de imágenes.

Por otro, lado si hablamos de problemas técnicos las imágenes de ultrasonido sufren de inconvenientes tales como: bajo contraste o baja relación señal / ruido, además de algunos artefactos [9] entre los cuales se encuentran temas como atenuación, resolución o misceláneos [10]. Otros retos técnicos que sufren las imágenes de ultrasonido son los que se mencionan en [9] donde se menciona que existe una “alta variabilidad de escaneo y un borde borroso” como parte de los problemas que se posee para la toma de imágenes de ultrasonido.

Por lo tanto, es importante aclarar que dentro de las estructuras craneales fetales existen varias que, de manera rutinaria, son analizadas por los médicos dentro de los exámenes de ultrasonido. Entre estas estructuras se incluyen:

- Ventrículos laterales (VI).
- Cavum Septum Pellucidum(CSP).
- Entre otras [7].

Pero para temas específicos de esta investigación solo se dio importancia a la estructura craneal llamada Cavum Septum Pellucidum(CSP). Normalmente la no visualización del CSP en ultrasonidos se asocia con malformaciones encefálicas como holoprosencefalia, displasia septo-óptica, agenesia de cuerpo calloso, enfermedad de Alexander, esclerosis tuberosa, facomatosis, pinealoma, trisomía del par y esquisencefalia. Además que se ha encontrado una anomalía en el CPS dentro de personas agresivas, alcohólicas o con trastornos neurológico, esto debido a que hay una presencia de un CSP alargado [11]. Teniendo en cuenta lo anterior, si se realiza una detección temprana sería una gran ayuda para el control y manejo de enfermedades o malformidades de los fetos, las cuales podrían disminuir las tasas de mortalidad o mejorar la calidad de vida de los pacientes afectados.

A lo largo de este planteamiento del problema se mencionaron los inconvenientes que se presentan con los procesos de toma de imágenes y como podrían llegar a afectar de manera circunstancial las tasas de falsos positivos o falsos negativos [9] pero en el siguiente numeral se presenta una clasificación de cada uno de los posibles errores que se desarrollan o con los que se enfrenta el personal médico encargado de la toma y análisis de imágenes creadas por procesos de ultrasonidos con cada uno de los artículos que respalda el problema en mención.

1.1.1. Problemas Clínicos y Técnicos que conlleva la toma de un ultrasonido

Como se observa en anteriores párrafos, el ultrasonido presenta una importancia alta en la medicina, pero este proceso conlleva una serie de retos los cuales pueden entorpecer la generación de un dictamen médico. En esta parte del documento se divide los posibles inconvenientes en dos grandes grupos, el primero son problemas técnicos y el segundo son los clínicos. El primer grupo corresponden a retos que se posee a nivel del dispositivo o de las necesidades específicas que requiere el mismo y el segundo grupo corresponde a problemas que tiene que ver con las condiciones físicas del feto, de la madre o del personal médico para la toma de imágenes ecográficas.

Todos estos inconvenientes se sintetizan en la Tabla 1 - Retos clínicos y técnicos del ultrasonido:

Tabla 1 - Retos clínicos y técnicos del ultrasonido

RETOS DEL ANALISIS DE IMÁGENES DE ULTRASONIDO		
RETOS TECNICOS		
Reto	Descripción	Tomado de
Costo	El costo del equipo de ultrasonido es alto	[12]
Mala configuración	errores en la configuración de la ganancia, puede hacer que ese desaparezca algunas formas al hacer algunas estructuras muy brillantes u opacas dependiendo de la configuración (bajo o alto contraste)	[10] [9]
Atenuación	“Amplitud reducida de ecos al intervenir estructuras con alta atenuación”	[10]
Resolución	“Se genera debido a la frecuencia de pulso, divergencia del haz o patrones de interferencia desde los ecos generados”	[10]
misceláneas	“Dos superficies reflectantes estrechamente espaciadas y ecos generados con forma cónica.”	[10]
Camino de propagación	“Cambio en la dirección de un pulso de sonido cuando cruza un límite y cuando ocurre un cambio en la velocidad del sonido”	[10]
Ilusión óptica	Es una alteración en la apariencia de la realidad debido al proceso de formación de la imagen	[10]
Ruido aleatorio	Este problema se presenta debido a temas como ganancia excesiva o configuraciones de la maquina	[10]
Calidad de la imagen	“contraste bajo y desigual con los fondos, formas irregulares, alta variabilidad de escaneo y un borde borroso”	[9]
Calidad de la imagen	“baja relación señal / ruido”	[9]
RETOS CLINICOS		
Reto	Descripción	Tomado de
Fisionomía del Paciente	El aumento del tejido adiposo materno dificulta la identificación en la imagen	[4]
Fisionomía del paciente	Formas de aire que pueden obstaculizar la toma del ultrasonido	[10]
Desconocimiento	Falta de familiaridad de los médicos con la patología	[4]
Desconocimiento	Poca experiencia del ecografista	[3] [4] [12] [9]
Anatomía	Anatomía cerebral complicada	[4]
Anatomía	la orientación del feto	[3] [4]
Anatomía	Se dificulta la toma de la imagen por temas como la corta longitud del tronco parietal fetal	[9]
Conocimiento	La delineación manual de estructuras detalladas requiere	[8]

	conocimientos anatómicos expertos	
Proceso	Tarea que requiere mucho tiempo y propensa a errores humanos	[8]
Proceso	alta movilidad del fetal, postura fetal o el oligohidramnios	[9]
Análisis de imágenes	discrepancias entre los observadores	[9]
Análisis de imágenes	la alta variabilidad intraclase y la baja similitud entre clases	[9]
Imágenes	Imágenes deficientes por temas tales como: errores del operador en la colocación del transductor, técnica incorrecta de escaneo o el ángulo de insonación incorrecto	[10]

Fuente: Adaptado de [3] [4] [8] [12] [10] [9]

Con lo anterior se puede determinar que existen una serie de barreras tanto técnicas como clínicas que dificultan una toma adecuada de ultrasonidos, generando de esta manera posibles errores en los dictámenes realizados por el personal médico.

Es aquí donde la aparición de estrategias como Deep Learning abren la posibilidad para una automatización del análisis de imágenes de ultrasonido. La razón principal para utilizar Deep Learning es debido a que esta área imita el razonamiento humano al utilizar muchas funciones de razonamiento simple, debido a este comportamiento se determina que sería una gran ayuda al proceso de lectura y detección de anomalías en imágenes de ultrasonido de fetos, además que ya se ha demostrado que funciona bien en el análisis de imágenes médicas [13]. Otro de los aspectos primordiales para la selección de este tema fue su factor innovador, esto debido a que el Deep Learning utiliza redes neuronales para el análisis de imágenes lo cual permite extraer de una manera más ágil, rápida y sencilla una serie de características de la imagen altamente representativas.

Teniendo en cuenta todos los anteriores temas tratados, se puede visualizar de manera corta todo el problema que actualmente se presenta en la toma de imágenes de ultrasonido y como el modelo de Deep Learning sería una estrategia viable para la automatización en la identificación de la estructura Cavum septum Pellucidum. Así de esta manera se podría brindar al personal médico una forma más sencilla de realizar el análisis de imágenes de ultrasonido y evitaremos los problemas ocasionados por inconvenientes clínicos o técnicos que se presentaron en el proceso de toma de imágenes.

1.2 FORMULACIÓN DEL PROBLEMA

Teniendo en cuenta los problemas anteriormente discutidos, con respecto a los aspectos técnicos y clínicos del procesamiento del ultrasonido fetal, se plantea la siguiente pregunta: ¿Cómo se pueden

apoyar los procedimientos de diagnóstico y análisis de anomalías en el desarrollo fetal, a partir de un sistema de reconocimiento automático de la estructura cerebral Cavum Septum Pellucidum basado en Deep Learning que utiliza imágenes de ultrasonido en 2D?

Además de la anterior interrogante, generamos las siguientes preguntas de sistematización que responden al desarrollo de los objetivos del proyecto:

- ¿Qué tipos de imágenes son adecuadas para el análisis del desarrollo cerebral y la detección de anomalías en el desarrollo del feto?
- ¿Cómo identificar dentro de las imágenes seleccionadas los distintos planos cerebrales que nos permitan identificar estructuras anatómicas?
- ¿Cuál metodología podría ser aplicada para el reconocimiento adecuado del Cavum Septum Pellucidum?

2 OBJETIVOS DEL PROYECTO

2.1 OBJETIVO GENERAL

- Desarrollar un sistema de reconocimiento automático de la estructura cerebral Cavum Septum Pellucidum basado en Deep Learning para el análisis de anomalías en el crecimiento del feto, utilizando imágenes de ultrasonido fetal en 2D

2.2 OBJETIVOS ESPECÍFICOS

- Seleccionar los criterios de recolección y procesamiento de las imágenes de ultrasonido fetal en 2D, para las etapas de entrenamiento, prueba y evaluación del modelo.
- Implementar un modelo de aprendizaje de máquina, para la identificación automática del plano cerebral y el reconocimiento del Cavum Septum Pellucidum en imágenes de ultrasonido fetal.
- Establecer las métricas de evaluación de la estructura clasificada en términos de su normalidad o anormalidad, para apoyar los criterios de diagnóstico en la práctica clínica.

3 MARCO TEÓRICO Y ANTECEDENTES

3.1 MARCO TEÓRICO

Para el entendimiento del proyecto realizado debemos tener muy en claro una serie de conceptos los cuales brindaran una ayuda básica para la comprensión del tema principal. Los conceptos a tener en cuenta son Ultrasonido, Tipos de ultrasonido, Procedimiento realizado en un ultrasonido, Estructuras Craneales en fetos, Ultrasonido aplicado al análisis Fetal, Sistema de procesamiento de imágenes y sus pasos fundamentales, además de una breve introducción al Deep Learning, los cuales serán desarrollados en los siguientes numerales.

3.1.1. Ultrasonido

Los ultrasonidos son ondas sonoras de alta frecuencias inaudibles para el oído humano, las cuales superan los 20 KHz (kilo-Hertz). Estas ondas normalmente se deforman con la interacción de tejidos, en algunos casos reflejan la onda directamente y en otros se dispersan en formas de ecos, estos ecos reflejados son los que permiten crear un mapa bidimensional de los tejidos [2].

Pero para entender cómo se llegó al proceso de ultrasonido que actualmente se maneja en centros hospitalarios se debe estudiar sus inicios. Todo el proceso de generación del ultrasonido tiene sus inicios con los estudios realizados por el naturalista y sacerdote Lazzaro Spallanzani quien en el año de 1793 realizó una serie de estudios de como el murciélago podía realizar vuelos en absoluta oscuridad, llegando a la conclusión que su oído era la principal clave para este comportamiento [2]. Además, para el año de 1912 el inglés L. F. Richardson sugirió la utilización de los ecos del ultrasonido para detectar objetos sumergidos. Luego de este primer posible uso del ultrasonido y unos pocos años después en el año de 1917 el médico francés Paul Langevin y el ruso Constantin Chilowsky produjeron el primer generador piezoeléctrico de ultrasonido, el cual generaba y recibía cambios eléctricos. Por otro lado, no fue hasta el año de 1942 donde el físico acústico Floyd Album Firestone crea el reflectoscopio el cual permitía detectar defectos internos en estructuras sólidas y da la base para la construcción de los ecógrafos actuales [2].

Como se detalla en el anterior párrafo la creación del reflectoscopio sentó las bases de la ecografía, esto debido a que cuando las versiones comerciales se aplicaron al cuerpo humano nació un nuevo mundo de posibilidades para el diagnóstico médico. Este proceso fue realizado en países tales como Japón, Estados Unidos y Suecia a finales de 1940 y principio de 1950. Las primeras personas que usaron este descubrimiento fueron, el Dr. I. Edler y el profesor C. H. Hertz en 1953 y lo aplicaron para la detección movimientos cardiacos (Ecocardiografía) [14].

Estos avances vinieron seguidos de grandes estudios que permitieron mejorar el proceso de ultrasonido. Pero no fue hasta los años 90 donde la tecnología de los ecógrafos sufrió de un gran desarrollo debido a los avances en temas como: microprocesadores, matrices de puertas de alta densidad, tecnología de montaje, disponibilidad de chips analógicos de bajo costo. Lo anterior hizo

posible que se dispusiera de una mayor capacidad de computación y un procesamiento más rápido en volúmenes más pequeños a costos más bajos lo cual conlleva a la inclusión de temas como:

- Adquisición de arquitecturas digitales y formadores de haces.
- Transferencia en vivo de imágenes para telemedicina.
- Transductores con anchos de banda más amplios y con configuración 1.5.
- Imágenes tridimensionales (avance logrado a finales de los 90s) [14].

Existen numerosos eventos históricos que contribuyeron al desarrollo del ultrasonido, algunos de los cuales se han mencionado en los párrafos anteriores. No obstante, a continuación, se presenta un resumen de otros eventos dentro la Tabla 2 - Momentos en la Historia del ultrasonido, los cuales son considerados como aspectos clave en la evolución del ultrasonido a lo largo de la historia:

Tabla 2 - Momentos en la Historia del ultrasonido

Evento	Persona o Personas involucradas	Año o fecha
Estudio de vuelo de murciélago	Lassaro Spallanzani	1793 [2].
Descubrimiento del fenómeno de piezoelectricidad	Pierre y Jacques Curie	1880 [2].
Detección de objetos sumergidos por medio de ultrasonido	L. F. Richardson	1912 [2].
Creación del primer generador pisa eléctrico utilizado para estudiar el fondo marino	Paul Langevin y Chilowsky	1917 [2].
Demostración experimental de la emisión de ultrasonidos por parte de los murciélagos	Donald Redfield Griffin	1938 [2].
Invencción del reflectoscopio	Floyd Album Firestone	1942 [2].
Introducción de los ultrasonidos como medios de diagnóstico en medicina. Esto en exploración de anomalías craneales	Karl Dussik	1942 [14]
Aplicación del método eco-impulso con finalidades biológicas	George Ludwig y Francis Stuthers	1949 [2].
Aparición del ultrasonido compuesto	No aplica	1951 [2].
Primeras imágenes bidimensionales del antebrazo en vivo	Douglas Howry, Dorothy Howry, Roderick Bliss y Gerald Posakony	1952 [2].
Aceptación del ultrasonido como instrumento de diagnóstico en medicina.	No aplica	1950 [2].
Introducción del scan converter.	No aplica	1970 [2].
Desarrollo de microprocesadores, matrices de puertas de alta densidad, tecnología de montaje, disponibilidad de chip analógicos de bajo costo lo que hizo posible que se dispusiera de una mayor computación y un procesamiento más rápido en volúmenes más pequeños a costos más bajos	No aplica	1990 [14]
Se posibilita la creación de imágenes en 3d en tiempo real	No aplica	1990 [14]

Fuente: Adaptado de [2], [14]

Como se observa en la Tabla 2 - Momentos en la Historia del ultrasonido, el desarrollo del ultrasonido ha recorrido un largo camino, y gracias a estos avances, hoy en día contamos con una tecnología que ha sido aplicada predominantemente en el ámbito médico. Para tener una mejor comprensión de este progreso, podemos observar la evolución del ultrasonido en imágenes dentro de la Figura 1 - Evolución del Ultrasonido.

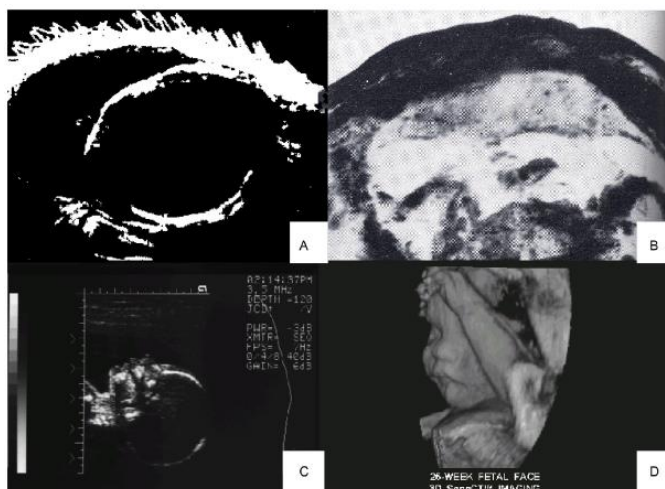


Figura 1 - Evolución del Ultrasonido

Imagen de evolución del diagnóstico en imágenes fetales. (a) cabeza de feto en blanco y negro (I. Donald, 1960); (b) imagen negativa temprana en escala de grises del feto de la década de 1970; (C) perfil fetal de alta resolución de la década de 1980; (D) cara y mano fetales renderizadas en superficie a partir de 2002 tomado de [14].

En la primera parte de la imagen se observa un estudio de imágenes fetales en blanco y negro llevado a cabo en 1960 (Imagen A) y la última imagen (Imagen D) se muestra un rostro fetal renderizado en superficie generado en 2002 [14].

3.1.2. Tipos de ultrasonido

Para entender un poco mejor el problema que es objeto de estudio dentro de este documento primero se analizará los tipos de ultrasonidos que actualmente se aplican en pacientes, para esto tomaremos como referencia lo que especifica el Instituto Nacional de Imagenología Biomédica y Bioingeniería de los Estados Unidos el cual menciona que existen dos tipos de ultrasonido, el primero es un ultrasonido terapéutico y el segundo es un ultrasonido diagnóstico [15].

El ultrasonido terapéutico es aquel que se usa para interactuar con los tejidos en el cuerpo humano ya sea para modificarlos o destruirlos, esto se realiza mediante el uso de rayos de muy alta intensidad, los cuales pueden destruir los tejidos enfermos o anormales [15]. El segundo tipo de ultrasonido es el usado para diagnóstico el cual es una técnica no invasiva que se utiliza para producir imágenes del cuerpo y se crean mediante una sonda la cual por medio de ondas sonoras crea una

imagen de la zona a diagnosticar, normalmente el dispositivo se coloca a nivel de la piel del paciente. Por otro lado, los ultrasonidos diagnósticos se pueden dividir en ultrasonido anatómico y ultrasonido funcional. Tal y como lo menciona [15] “El ultrasonido anatómico es aquel que produce imágenes de órganos internos u otras estructuras y el ultrasonido funcional combina información como el movimiento y la velocidad del tejido o la sangre, la suavidad o la dureza del tejido, y otras características físicas, con imágenes anatómicas para crear “mapas de información””.

Dentro del desarrollo del proyecto solo se tuvo en cuenta los ultrasonidos de tipo diagnóstico y dentro de esta categoría solo se tomó los de tipo anatómico debido a que se realizó los análisis sobre imágenes en 2D de la estructura craneal fetal Cavum Septum Pellucidum.

3.1.3. Procedimiento realizado en un ultrasonido

En este capítulo analizamos un poco acerca de los tipos de ultrasonidos debemos conocer como es el proceso que se lleva a cabo para la toma de un ultrasonido actualmente, para esto se debe comprender que este proceso es uno de los métodos más utilizados hoy en día, debido a que es un procedimiento no invasivo el cual posee unos costos muy bajos y permite el análisis de imágenes en tiempo real [3].

Como ejemplo se tiene la encuesta realizada por [12] donde visualiza el uso del ultrasonido en países de ingresos medios o bajos tales como Colombia. En este documento los autores especifican que el ultrasonido ha experimentado un rápido crecimiento en las aplicaciones de diagnóstico, evolucionando de una herramienta solo para radiólogos o cardiólogos a una tecnología pilar en la práctica clínica moderna. Dentro de la anterior encuesta se resalta los siguientes resultados, el 45% dicen que la frecuencia de uso de los ultrasonidos es diaria, además que el 80% de los encuestados no tienen o tienen alguna experticia en los procesos de toma de ultrasonidos [12].

Cabe desatacar que el proceso de ultrasonido funciona por medio de un equipo médico (ecógrafo) que se compone de una CPU, encargada de los cálculos y la visualización de las imágenes, además de un transductor (sonda) que emite ondas de sonido [16], este dispositivo además de generar permite detectar los ecos reflejados por el ultrasonido. En la mayoría de casos el transductor está compuesto de elementos activos hechos en materiales especiales de cristal cerámico llamados piezoeléctricos. Los anteriores materiales permiten al dispositivo no solamente producir ondas sonoras sino también producen un campo electromagnético cuando reciben una onda de retorno.

El proceso para la generación de la imagen de ultrasonido es el siguiente, el transductor (sonda) envía un haz de ondas sonoras dentro del cuerpo humano, las cuales se reflejan al dispositivo por los límites entre los tejidos en la trayectoria del haz. Cuando los ecos llegan al transductor se generan señales eléctricas que son enviadas a la CPU (escáner de ultrasonido). El escáner teniendo en cuenta la velocidad y el tiempo de regreso de cada eco calcula la distancia entre el transductor y el límite de los tejidos. Las anteriores distancias son utilizadas para generar imágenes bidimensionales de los

tejidos y de los órganos. Durante el examen normalmente el técnico coloca el transductor a nivel cutáneo (o en algunos casos interno) y aplicara un gel el cual evitara que se formen bolsas de aire entre el transductor y la piel [15].



Figura 2 - Transductor para ultrasonidos

dispositivo utilizado por los ultrasonidos para la toma de imágenes, Tomado de [15].

Por último, la CPU despliega en pantalla y en tiempo real la imagen creada, la cual permite una visualización de los órganos o estructuras craneales en tiempo real

3.1.4. Estructuras Craneales en fetos

Dentro de las estructuras craneales fetales se poseen varias que normalmente son analizadas por los médicos dentro de los exámenes de ultrasonido entre estas encontramos:

- Ventrículos laterales (VI).
- Cavum Septum Pellucidum(CSP).
- Tálamo (Th).
- Cerebelo (Ce).
- Plexo coroideo (CP).
- Cisterna magna (CM) [7].

Pero para temas específicos de esta investigación se realizó un enfoque en la estructura craneal llamada Cavum Septum Pellucidum (CSP), la cual se encuentra dentro del Septum Pellucidum. A continuación, se procede a detallar cada uno de los componentes de la estructura craneal con el fin de proporcionar una comprensión más profunda del tema.

El Septum Pellucidum es un delgado tabique medial de morfología triangular, formado por dos laminas nerviosas adheridas que se localizan en el cuerpo calloso y el triángulo (fórnix). durante la vida intrauterina existen tres cavidades potenciales las cuales son el Cavum Septum Pellucidum (CSP), el Cavum Vergae (CV) y el Cavum del velo interpósito (CVI) [11].

La estructura Cavum Septum Pellucidum (CSP), es un estrecho intervalo que se encuentra entre las dos laminas que componen el Septum Pellucidum, normalmente como lo dice [17] “Su forma es trigonal de base anterior y vértice posterior, sus láminas se unen cranealmente a la superficie cóncava inferior del tronco, rodilla y pico del cuerpo calloso”. Para tener una mayor claridad de donde se encuentra la estructura Cavum Septum Pellucidum se puede observar en la Figura 3 - Ubicación del Cavum Septum Pellucidum (señalado con una flecha):




Figura 3 - Ubicación del Cavum Septum Pellucidum

la imagen se señala un Cavum Septum Pellucidum normal, Tomado de [11].

Normalmente la no visualización de esta estructura que se encuentra en todos los fetos (mayormente en mujeres) de 36 semanas y permanece en el 36% de los nacidos [9], se puede asociar con malformaciones encefálicas como holoprosencefalia, displasia septo-óptica, agenesia de cuerpo calloso, enfermedad de Alexander, esclerosis tuberosa, facomatosis, pinealoma, trisomía del par y esquisencefalia [11].

3.1.5. Ultrasonido aplicado a análisis fetal

El ultrasonido bidimensional o tridimensional es una técnica imprescindible en el control de gestación, esto debido a la sensibilidad y especificidad para el diagnóstico fetal. Además, esto no conlleva ningún riesgo para ninguno de los pacientes. Las ecografías se realizan en la paciente embarazada en tres momentos, el primero entre las 11-12 semanas, el segundo alrededor de las 20 semanas y el tercero entre las 32 y 36 semanas [18].

Desde 1942 se evidencia que los ultrasonidos han sido aplicados para la detección de anomalías craneales [14]. Esto demuestra claramente que, desde hace varias décadas, se ha reconocido el gran potencial de los exámenes de ultrasonido en el análisis de imágenes craneales fetales. Siendo así que una de las áreas de mayor aplicabilidad del ultrasonido es la medicina y especialmente la obstetricia, donde se utiliza para temas tales como: la identificación del sexo de un bebe [19], identificación de posible cromosomopatía fetal, malformaciones congénitas y en general para determinar la salud general del Feto [18]. Por otro lado, según recomendaciones de la International Society of Ultrasound in Obstetrics and Gynecology (ISUOG) se debe considerar las siguientes evaluaciones por ultrasonido: Biometría fetal, placenta, líquido amniótico y hemodinamia fetal [20]

3.1.6. Sistema de procesamiento de imágenes y sus pasos fundamentales

Dentro de este numeral se define los aspectos principales dentro de un sistema de procesamiento de imágenes, en primera instancia podemos definir el procesamiento de imágenes digitales como una alteración de la información visual para obtener mejores resultados o para aislar algunas características particulares de la imagen [21].

El campo de procesamiento de imágenes se refiere a un tratamiento que se realiza por medio de una computadora, esto debido a que las máquinas de imágenes cubren casi todo el espectro electromagnético, además que estas pueden operar con imágenes generadas por fuentes que los humanos no están acostumbrados a asociar como imagen, entre las cuales se pueden encontrar ultrasonidos, microscopia electrónica, entre otros [19].

El procesamiento de imágenes se remonta a la industria de los periódicos, esto ocurrió debido al envío de imágenes por cable submarino entre Londres y New York en el año de 1920, lo cual redujo el tiempo requerido para transportar una imagen de una semana a tres horas. El proceso finalizó con el uso de una serie de equipos especializados que codificaron las imágenes y luego las reconstruyeron en el receptor. Para la década de 1960 y con el desarrollo de computadoras lo suficientemente poderosas para las tareas de procesamiento de imágenes, empiezan a aparecer técnicas para ser utilizadas en imageneología media, observaciones remotas de los recursos terrestres y astronomía. Además, para el año de 1970 se empiezan a destacar avances tales como la tomografía axial computarizada, la cual es considerada como una aplicación del procesamiento de imágenes en el diagnóstico médico. A continuación se recalca que desde la década de los 60s hasta ahora, el campo del procesamiento de imágenes ha crecido vertiginosamente y todo este crecimiento está muy ligado a la evolución de las computadoras digitales, la disminución en la relación entre el precio, el rendimiento de las computadoras, la expansión de las redes y el ancho de banda de comunicación a través de Internet [19].

Las principales tareas de aplicación de los sistemas de procesamiento de imágenes están asociadas con la medicina y con la extracción de información de una imagen, de una forma adecuada para el procesamiento informático, tales como momentos estadísticos, coeficientes de transformada de Fourier y medidas de distancia multidimensionales.

Teniendo en cuenta que se abordó temas sobre que es un sistema de procesamiento de imágenes y un poco de su historia, se dará mención sobre cuáles son los pasos fundamentales en un procesamiento de imágenes, los cuales se encuentra en la Tabla 3 - Pasos del procesamiento de imágenes, donde se describe cada uno de los pasos:

Tabla 3 - Pasos del procesamiento de imágenes

Paso	Descripción
Adquisición de imagen	Este paso es tan sencillo como la adquisición de una imagen que ya se encuentra en forma digital.
Filtrado y Mejoramiento de imágenes	Es el proceso de manipulación de una imagen para que el resultado sea mejor que el original.

Restauración de la imagen	Es el proceso que se enfrenta con el mejoramiento de la apariencia de las imágenes
Procesamiento de color de la imagen	Es un área que ha venido ganando importancia debido al incremento en el uso de imágenes digitales a través internet.
Ondas y otras transformaciones de imágenes	Las ondas son la base para representar imágenes en varios grados de resolución.
Compresión y marcas de agua	Este paso se enfrenta a las técnicas para reducir el almacenaje requerido para guardar una imagen o el ancho de banda requerido para su transmisión
Procesamiento morfológico	Este paso se encarga de las herramientas para la extracción de componentes de las imágenes que son útiles en la representación y descripción de la forma.
Segmentación	La segmentación divide una imagen en sus partes y objetos que la constituyen. Además que la segmentación autónoma de imagen suele ser una de las tareas más difíciles del procesamiento digital de imágenes.
Características de extracción	Es el paso que le sigue a la segmentación y consiste en la detección y descripción de características.
Clasificación de patrones de imagen	Es el proceso que asigna una etiqueta a un objeto en función de sus descriptores de características

Fuente: Adaptado de [19].

En la Figura 4 - Interacción de pasos en un sistema de procesamiento de imágenes se observa la interrelación entre cada uno de los pasos del procesamiento de imágenes.

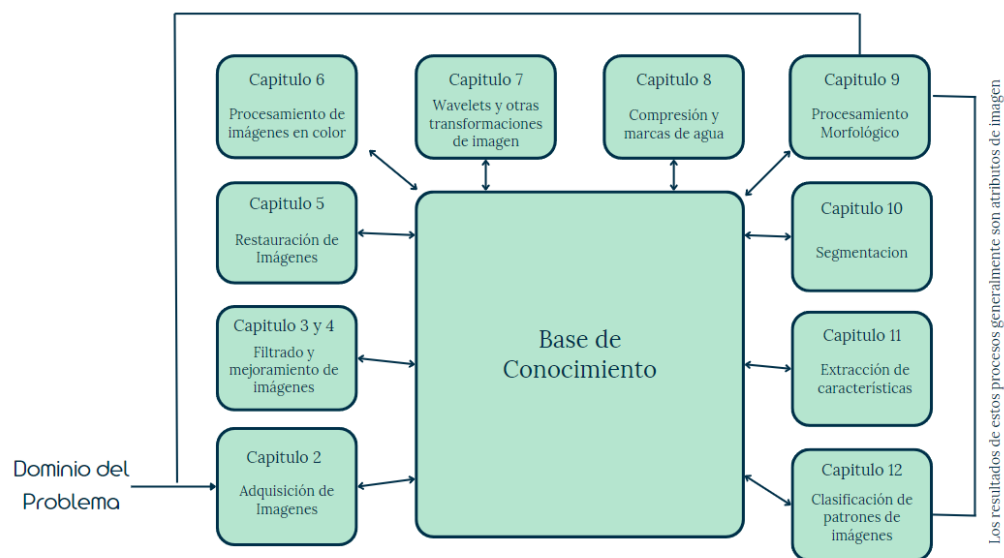


Figura 4 - Interacción de pasos en un sistema de procesamiento de imágenes

La figura muestra cada uno de los pasos que tiene un sistema de procesamiento de imágenes y cómo interactúan entre ellos, Traducido de [19].

3.1.7. Deep Learning

En primera instancia antes de definir el Deep Learning debemos entender que es el aprendizaje automático (machine Learning), esto debido a que el aprendizaje profundo es parte de la informática y un sub campo del mismo [22].

La definición de machine Learning o aprendizaje automático fue introducida en 1959 por Arthur Samuel. En esta definición el autor menciona que “el aprendizaje profundo es una rama de la inteligencia artificial cuyo fin es dotar a una maquina (por medio de algoritmos) de la capacidad de entrenar y aprender a partir de datos, sin ser explícitamente programada, imitando la capacidad que tienen las personas de aprender mediante ejemplos”. El aprendizaje automático puede clasificarse en aprendizaje supervisado, no supervisado, semi supervisado y de reforzamiento, cada uno de los cuales tiene un comportamiento de acuerdo sus variables dependientes [23].

Teniendo en cuenta la definición de Machine Learning del anterior párrafo, se procede a comprender que el aprendizaje profundo es una sub rama de la Machine Learning [22] que ha roto con el paradigma de generar programas computacionales que se desarrollan con una serie de reglas para solucionar un problema en particular, es decir que con este avance se ha permitido a las maquinas resolver problemas sin que sean programadas con algún algoritmo. Los algoritmos de esta manera pasan a emular el comportamiento del cerebro humano y en esencia tienen como bandera un modelo de redes neuronales [23].

Pero el Deep Learning, aunque se presenta como un tema nuevo, tuvo sus inicios en 1940 y tiene tres momentos los cuales los marcaron el desarrollo de esta tecnología, estos momentos fueron:

- Desarrollo de teorías de aprendizaje biológico (Mc Colloch,1943) y la implementación del perceptrón (Roseblatt, 1958).
- Desarrollo de algoritmos de retro propagación (Rumelhart y otros, 1986).
- Entrenamiento de redes neuronales profundas (Hinton G, 2006) [23].

Así es como se puede determinar que uno de los principales componentes dentro del Deep Learning son las redes neuronales, las cuales se dividen en dos tipos las convolucionales y las recurrentes [23]. Dentro de estos dos tipos de redes la que más nos interesa por motivos de la investigación son las convolucionales, esto debido a que se relacionan directamente con el procesamiento de imágenes y al proceso de emular el sistema de percepción visual del ser humano. Este tipo de redes neuronales han sobrepasado por mucho a los modelos tradicionales tales como regresión lógica, arboles de decisión o las mismas redes neuronales tradicionales [23].

Las redes neuronales convolucionales a diferencia de otros modelos permiten obtener automáticamente características y transformaciones a partir de las cuales se forman capas de

neuronas. Esto permite a la red neuronal el procesamiento de conocimiento con mayor facilidad [23]. Todo lo anterior ayuda a concluir que el Deep Learning junto con sus técnicas ofrecen posibilidades de aprendizaje casi infinitas, debido a que con capaces de generar una inferencia de conocimiento en forma significativa [22].

3.2 ANTECEDENTES

Para el desarrollo de los antecedentes debemos tener en cuenta que se realizaron dos revisiones dentro de las cuales se obtuvieron artículos que respaldaron los dos temas principales de este proyecto en la primera sección 3.2.1 Antecedentes del proyecto se evidencian estudios previos sobre el mismo tema del proyecto, mientras que en la sección 3.2.2 Antecedentes para la determinación de la anomalía de la estructura Cavum Septum Pellucidum se exponen documentos que validan formas para la detección de anomalías en la estructura Cavum Septum Pellucidum

3.2.1. Antecedentes del Proyecto

Dentro del desarrollo de este proyecto se realizó un análisis del estado del arte dentro del cual se determinó que actualmente existen un gran número de artículos e investigaciones que tienen como foco de aplicación al Deep Learning en a las imágenes generadas por ultrasonido para la detección de posibles anomalías en fetos. Pero fueron muy pocos los que se centraban en la estructura craneal Cavum Septum Pellucidum, por lo que el proyecto incursiona en el análisis de esta estructura. En la Tabla 4 - Antecedentes Deep Learning en Ultrasonido se especifican datos tales como: el nombre del documento, tipo de documento, una descripción del trabajo y como abordaron el problema, referencia del documento, además de como aportó el documento al sistema de identificación de la estructura y las diferencias con el proyecto en desarrollo.

Tabla 4 - Antecedentes Deep Learning en Ultrasonido

Primer Artículo	
Using deep-learning algorithms to classify fetal brain ultrasound images as normal or abnormal	
Tipo de documento	Ref.Doc
Artículo	[13]
Descripción del documento	
El artículo plantea la implementación de un modelo de Deep Learning en ecografías neonatales. Teniendo como objetivo que los algoritmos pudieran cumplir con tres propósitos:	
<ul style="list-style-type: none"> • Realización de segmentación de imágenes a lo largo del cráneo fetal • Clasificación de la imagen como normal o anormal. • Localización de la lesión. 	
Para esto se eligió redes convolucionales y mapas de calor como medio para la identificación de anomalías o normalidades craneales en fetos	
Forma de abordar el problema	
El problema en cuestión fue abordado en una serie de etapas las cuales fueron:	

- Adquisición de datos (se determinó la base de imágenes y criterios de inclusión).
- Procesamiento previo de datos (se realizaron ajustes para cumplir con un término de similitud, junto con ajustes de rotación)
- Estructura de la red neuronal para el entrenamiento (se realizó por medio de tres sub etapas las cuales fueron
 - (1) Segmentación craneoencefálica, para eliminar áreas distractoras. Segmentación es decir dividir una imagen en varias regiones separadas
 - (2) Clasificación de imágenes como normales o anormales, en otras palabras, el sistema fue diseñado para producir una clasificación binaria.
 - (3) Localización de lesiones, utilizando mapas de calor e imágenes superpuestas

Clasificación como anormal y normal teniendo en cuenta mapas de calor

Diferencias con el proyecto

El artículo afronta un diagnóstico simple y se aplica a un conjunto de anomalías, mientras que nuestro proyecto estará más enfocado a una estructura particular y permitirá un análisis más profundo. Además el estudio también está enfocado a la identificación de lesiones en lo cual difiere de nuestro proyecto debido a que no identificaremos lesiones si no una posible anomalía de la estructura CSP

Aportes del documento al proyecto

El artículo como tal brinda una forma para la aplicación de Deep Learning (redes convolucionales) en imágenes de ecografías, lo cual nos permite dar una idea de las necesidades del modelo y como aplicarlo a la estructura craneal que estudiaremos.

Segundo Artículo

Automatic Deep Learning-Based Pipeline for Automatic Delineation and Measurement of Fetal Brain Structures in Routine Mid-Trimester Ultrasound Images

Tipo de documento	Ref.Doc
Artículo	[3]

Descripción del documento

El artículo plantea la creación de un pipeline de ultrasonidos con aprendizaje profundo para delinear y medir automáticamente varias de las estructuras cerebrales más importantes en imágenes de ultrasonido cerebral fetal.

Forma de abordar el problema

El artículo muestra que el problema fue desarrollado en las siguientes etapas:

- Adquisición de imágenes: se tomaron las imágenes de un conjunto compuesto por 12.400 imágenes de ultrasonido. Las imágenes fueron adquiridas en BCNatal (Hospital Clínic de Barcelona y Hospital Sant Joan de Déu, Barcelona, España)
- Preparación de los datos: se realizaron mediciones y delaciones manuales con el fin de entrenar y validar los modelos de Deep Learning.

- Creación de pipeline que consta de tres pasos:
 - (1) Clasificación automática de planos: Para la clasificación se usó una ResNet-18 (Red Neuronal Residual).
 - (2) Delineación automática de estructuras: dentro de este proceso se usó DeepLab CNN.
 - (3) Mediciones automáticas. En esta sub etapa se desarrollaron diferentes ecuaciones y métodos para estimar a partir de las ROI los parámetros y medidas biométricos propuestos de forma automática.

Análisis estadístico: se evaluó el rendimiento del pipeline automático comparando los resultados de cada paso con la verdad fundamental obtenida por procesos de clasificación manual

Diferencias con el proyecto

El artículo muestra que el proyecto se aplicó a más de una estructura craneal (Cavum Septum Pellucidum, cuerno superior, cuerno inferior, ventrículo lateral, tálamo superior, tálamo inferior, fisura silvana, fisura interhemisférica y el cerebelo), mientras que nuestro proyecto plantea en énfasis en una de ellas.

Además, el proyecto realiza otros tipos de mediciones como la circunferencia de la cabeza, diámetro biparietal, diámetro occipitofrontal y el índice cefálico, las cuales no se tendrán en cuenta para este proyecto. Es decir nuestro proyecto tuvo un mayor alcance y mayor profundidad en la estructura Cavum Septum Pellucidum.

Aportes del documento al proyecto

En este artículo se tiene en cuenta la misma estructura craneal (Cavum Septum Pellucidum) que se estudió en el proyecto, lo cual nos da un aval que el proceso ha sido realizado con anterioridad y su aplicación fue exitosa. Adicionalmente nos brinda una serie de pasos de cómo podemos estudiar mejor nuestra estructura craneal.

Por otro lado, dentro de la creación del pipeline nos indica que también se usaron redes convolucionales (ResNet-18, Red Neuronal Residual) para el desarrollo del proyecto, lo que no dio indicios de cuál es la mejor manera para desarrollar el estudio propuesto.

Tercer Artículo

An Automated Deep Learning Model for the Cerebellum Segmentation from Fetal Brain Images

Tipo de documento	Ref.Doc
Artículo	[24]

Descripción del documento

En el artículo se presenta una técnica de Deep Learning para la segmentación automática del cerebelo fetal, esto a partir de imágenes cerebrales ecográficas en 2D, para lo cual utilizan una segmentación por medio de una ReU-Net (Region-enhanced nuclei segmentation network) y como modelo de cimentación se implementa una U-Net

Forma de abordar el problema

El artículo muestra que el problema en mención fue desarrollado mediante la aplicación de una ReU-Net (Region-enhanced nuclei segmentation network) y fue desarrollado en las siguientes fases:

- **Adquisición de imágenes:** el conjunto de datos de imágenes cerebrales de ultrasonido fetal se recopila del sitio web estándar Kaggle.
- **Desarrollo y entrenamiento de red Neuronal:** se desarrolla una nueva ReU-Net y se capacita en el sistema para segmentar el cerebelo a partir de imágenes cerebrales fetales.
- **Afinamiento de la red neuronal:** se realiza la función de pre-procesamiento para eliminar los errores y el ruido no deseado en las imágenes cerebrales de ultrasonido utilizando el filtro Wiener.
- **Implementación:** se ha empleado ReU-Net para entrenar y segmentar el cerebro
- **Evaluación:** el desempeño del modelo propuesto se validó y evaluó con respecto al recall, la precisión, la puntuación F1, la Distancia de Hausdorff (HD) y la precisión.

Cabe aclarar que aunque el autor no especifica estas como etapas, se decide colocar un nombre a cada uno de los factores relevantes ofrecidos por el proyecto.

Diferencias con el proyecto

La principal diferencia con el proyecto es que esta se centró exclusivamente en el cerebelo la cual difiere de la estructura que analizaremos en el presente documento. Además que para el presente documento se difirió en la técnica (ReU-Net) ya que se ha seleccionado un método (U-net con Vgg16) para la identificación del Cavum Septum Pellucidum y sus posibles anomalías.

Aportes del documento al proyecto

Dentro de los temas tratados en el artículo podemos observar que se implementa una ReU-Net (Region-enhanced nuclei segmentation network) y una U-Net, lo cual nos da una referencia o posible medio para el desarrollo de nuestro proyecto.

Otro de los aportes del artículo fue la introducción a temas tales como:

- Clasificadores basados en Deep Learning (DLC).
- Arquitectura Deep Learning: CNN (convolucionante) es la arquitectura más ampliamente usada.
- Diseños Deep Learning Basados en auto encodificadores
- Redes Generativas Adversariales (GANs)
- Máquinas Boltzmann restringidas(RBM)
- Estructuras de Deep Learning Basadas en Codificación Dispersa
- Redes neuronales recurrentes (RNNS)

De los anteriores temas nos llamó mucho la atención los DLC, los cuales abren la posibilidad a desarrollar de mejor manera el proyecto, esto debido a que pueden procesar directamente imágenes crudas, eliminando el requisito de pre-procesamiento, segmentación y extracción de características

Cuarto Artículo

Standard fetal ultrasound plane classification based on stacked ensemble of deep learning models

Tipo de documento	Ref.Doc
Articulo	[25]

Descripción del documento

El artículo plantea la creación de una identificación automatizada de planos de ultrasonido fetal estándar de uso común, basados en el conjunto de apilamiento de redes neuronales convolucionales profundas (CNN).

Dentro del desarrollo del artículo los autores usaron un grupo de redes convolucionales junto a algunos algoritmos de clasificación para obtener los siguientes resultados del modelo:

- Una exactitud del 95,69%
- Precisión del 94,02%
- recall del 96,28%
- F1-score del 95,08%
- Especificidad del 99,12%
- Coeficiente de correlación de Matthews del 94,19%

El método propuesto por los autores incluye dos módulos uno de extracción de señales y el de clasificación.

Forma de abordar el problema

Teniendo en cuenta que una de las tareas más tediosas para los ecógrafos es la creación de planos estándar del feto. Se propone la creación de un apilamiento de redes neuronales convolucionantes, las cuales fueron entrenadas previamente. Las tres redes utilizadas fueron:

- AlexNet
- VGG-19, VGG-19 modificado
- DarkNet-19

Luego del apilamiento de redes, se utilizaron los algoritmos de clasificación Softmax y Random forest para el proceso de predicciones de cada red. Por último se utilizó la técnica de voto por mayoría absoluta en los procesos de predicción de cada modelo.

Diferencias con el proyecto

El proyecto expuesto en este artículo difiere de nuestro trabajo en que realiza la clasificación de planos de ultrasonido en seis clases diferentes, las cuales son:

- Abdomen
- Cerebro
- Fémur
- Tórax
- Cuello uterino materno
- Otros planos fetales

Y nuestro trabajo planteo la identificación de posibles anomalías de la estructura Cavum Septum Pellucidum, es decir que realizamos un análisis más profundo de una parte específica del crecimiento del feto.

Aportes del documento al proyecto

Este artículo plantea una nueva visión para el desarrollo de nuestro proyecto debido a que nos presentó la posibilidad de realizar un apilamiento de redes neuronales que comparadas con la aplicación individual de cada una no tendrían los mismos niveles de exactitud, precisión, recall, entre otros. Esto permitió que tuviéramos un referente sobre una nueva forma para trabajar en el Deep Learning. Por otro lado, el artículo nos colaboró con el entendimiento de la aplicación de algoritmos de clasificación como lo son softmax y random forest. Lo anterior generó una ayuda que difiere de los otros documentos debido a que en pasados artículos no se menciona ninguna técnica o algoritmo de clasificación. Otro de los aspectos innovadores que ofreció el artículo es el concepto de redes convolucionantes pre-entrenadas esto para extraer las representaciones espaciales semánticas de imágenes de ultrasonido fetal.

Quinto Artículo

Ultrasound Medical Images Classification Based on Deep Learning Algorithms: A Review

Tipo de documento	Ref.Doc
Artículo - review	[4]

Descripción del documento

Dentro del artículo se generó una revisión de los estudios que se han realizado respecto al desarrollo de Deep Learning y redes neuronales (convolucionales y recurrentes), todo aplicado a las tareas de segmentación y clasificación de imágenes ecográficas

Forma de abordar el problema

En este artículo se realizó una revisión para encontrar los enfoques más recientes y eficientes que han tenido los investigadores sobre los temas de clasificación de imágenes de ultrasonido en el área del Deep Learning. Para este proceso los autores realizaron un análisis de 12 artículos recientes (mayores a 2018) en los cuales se ven como se aplica el Deep Learning y las redes neuronales para el análisis de imágenes de ultrasonido. Entre las redes utilizadas podemos encontrar redes convolucionales (CNN), redes Recurrentes (RNN), redes neuronales convolucionales basadas en región (R-CNN), redes auto codificadas (FCN), entre otras.

Diferencias con el proyecto

El artículo difiere de nuestro proyecto de grado en que este es una recopilación de los últimos enfoques que han tenido los investigadores en el área de Deep Learning aplicado al análisis de imágenes de ultrasonido, mientras que nuestro proyecto plantea la creación de un modelo que permitió el análisis de la estructura CSP. Es decir nuestro proyecto es un proyecto aplicado.

Aportes del documento al proyecto

El aporte que nos brindó este artículo fue la identificación de los enfoques más utilizados y los métodos de mayor precisión logrados. Además de contar con un resumen que incluye detalles tales como: el uso de algoritmos, arquitecturas de aprendizaje profundo, conjuntos de datos, los hallazgos logrados, las estrategias y desafíos en el entrenamiento de modelos profundos. Todo lo anterior nos colaboró para identificar las tendencias que se están aplicando y cómo podríamos abordar el desarrollo de nuestro proyecto.

Fuentes: Adaptado de [4], [25], [24], [3], [13]

Para la selección de estos artículos se consideró que no tuvieran fechas inferiores a 5 años y que todos aplicaran el Deep Learning como método para la solución de la problemática que se mencionaba en cada uno de ellos. Algunos de los artículos son revisiones sistemáticas que contienen un agrupado de muchos otros artículos que están alineados con las necesidades del presente proyecto.

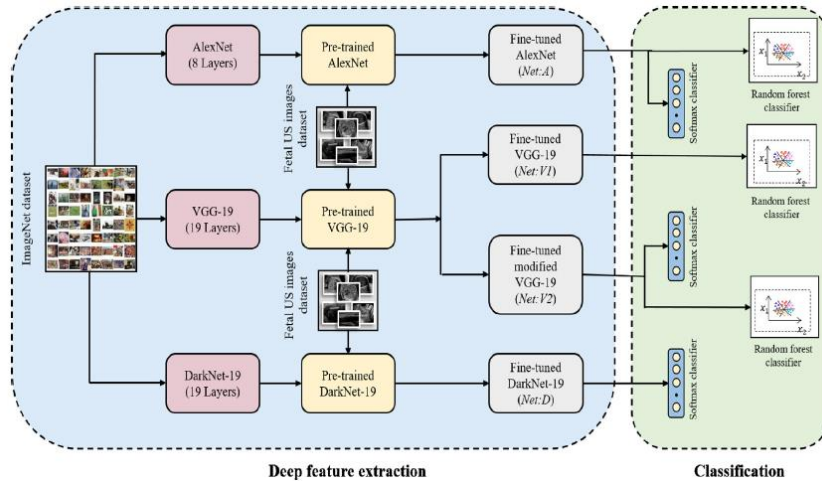


Figura 5 - Componentes de solución

Muestra los componentes de una solución Deep Learning, Fuente: tomada de [25]

3.2.2. Antecedentes para la determinación de la anomalía de la estructura Cavum Septum Pellucidum

Durante el desarrollo del último objetivo de este proyecto, se realiza un análisis del estado del arte, el cual permite determinar que actualmente existen algunos artículos e investigaciones centrados en la determinación de posibles anomalías dentro de la estructura Cavum Septum Pellucidum. Sin embargo, pocos se enfocan en una determinación clara de los principales aspectos que podrían evidenciar un problema en la estructura analizada. Por esta razón, el proyecto toma como referencia aspectos tales como tamaño o dimensiones. En la Tabla 5 - Revisión Sistemática Anomalías del Cavum Septum Pellucidum se presentan datos tales como: el nombre del documento, tipo de documento, una descripción del trabajo y como determinaron una posible anomalía de la estructura, referencia del documento, además de como aporta el documento al proceso que se está creando.

Tabla 5 - Revisión Sistemática Anomalías del Cavum Septum Pellucidum

Primer Artículo			
Can Cavum septum Pellucidum width and length measurements also be reliable indicators of corpus callosum measurements in normal fetuses?			
Tipo de documento	Articulo	Ref.Doc	[26]
Descripción del documento			
El objetivo general del artículo es examinar como la asociación entre las mediciones de largo y ancho del			

Cavum Septum Pellucidum (CSP) y del cuerpo calloso (CC) pueden o no estar asociadas con una anomalía.

En este estudio se examinó a cerca de 152 mujeres a las cuales se les realizaron procesos de exámenes ecográficos para la detección de anomalías fetales durante mediados del tercer trimestre de embarazo. Todos los datos fueron tomados entre marzo de 2024 y julio de 2024 en el departamento de perinatología del hospital de la ciudad de izmir en izmir Turquía.

Como resultado final de la investigación se obtuvieron los siguientes resultados:

- La longitud media del CSP fue de 7,96 más o menos 1.09 milímetros y de ancho 3.43 más o menos 0.82 milímetros.
- La longitud media del CC fue de 20 más o menos 3.76 milímetros y el ancho 3.14.mas o menos 0.82 milímetros.
- Hay una correlación positiva entre las longitudes del CSP y el CC.
- Existe una correlación significativa entre los anchos anterior, medio y posterior del CSP y CC
- Todas las mediciones del CSP y el CC se correlacionaron con la edad gestacional, el diámetro biparetal y la circunferencia de la cabeza.
- La relación CSP no se relacionó con las dimensiones CC.

Como conclusión del estudio se obtuvo que tanto la longitud como el ancho de las estructuras CC y CSP se desarrollaron entre sí en fetos normales. Adicionalmente se agrega que el Cavum Septum Pellucidum es uno de los punto de guía más importantes en la evaluación del cerebro fetal, además de ser uno de los parámetros más importantes en los exámenes de ultrasonido de rutina.

Forma de Identificar la anomalía de la estructura

Para la identificación de la forma de la estructura se tomó en cuenta que el desarrollo de CSP comienza en la semana 10 a 12 y se completa en la semana 17 de gestación, este suele desaparecer al final del embarazo cuando la lámina septi pellucidi se fusiona y se convierte en un solo Septum Pellucidum. Teniendo en cuenta este tipo de estudio se menciona que una ausencia o forma anormal puede ser un indicador de anomalías cerebrales fetales. Otro aspecto que cabe la pena resaltar es que también se menciona que no solamente la obtención de imágenes de la estructura CSP es suficiente para indicar un desarrollo cerebral fetal normal. Pero si aclara que la evaluación ecográfica del CSP fetal puede proporcionar información sobre posibles anomalías o patologías que pueden estar asociadas con su apariencia o ausencia.

Aportes del documento al proyecto

El artículo brinda tres grandes aportes al proceso de detección de una posible anomalía. En primer lugar, se menciona una referencia directa que especifica que, en ausencia o con una forma anormal de la estructura CSP, se puede inferir una posible anomalía. En segundo lugar, el artículo proporciona rangos de tamaño por semana, lo que permite establecer un rango de normalidad. Por último, incluye un componente en el que se especifica el tamaño del CSP a lo largo del proceso de gestación del feto.

Segundo Artículo

Reference Ranges for Corpus Callosum and Cavum Septi Pellucidi Biometry on Prenatal Ultrasound

Tipo de documento	Articulo	Ref.Doc	[27]
-------------------	----------	---------	------

Descripción del documento

Este artículo realizó una revisión sistemática y un meta análisis de nomogramas publicados sobre la biometría del cuerpo calloso y el Cavum Septi Pellucidum, llegando a una serie de hallazgos que enfatizan en la necesidad de estandarizar los protocolos de investigación y los criterios de publicación para los rangos biométricos normales. Todo el proceso de búsqueda bibliográfica se llevó a cabo el 15 de junio de 2020 y se actualizó en enero de 2021. Dentro del proceso de selección se encontraron un total de 988 ítem y se eliminaron 301 por duplicidad, lo que resultó en un total de 687 citas. De las anteriores citas 440 hicieron referencias al Cavum Septi Pellucidum o al cuerpo calloso y fueron los seleccionados para ser revisados más a fondo. Luego de revisados los documentos minuciosamente se determinó que solo 26 de ellos cumplieron con los criterios para la revisión de texto completo.

Forma de Identificar la anomalía de la estructura

La forma utilizada por los autores para calcular los rangos de normalidad de las formas cuerpo calloso y el Cavum Septi Pellucidum fue por medio de la toma de datos como la media y las desviaciones estándar de cada uno de los estudios. Los datos que se obtienen como mediana, primer y tercer cuartil se transforman a partir de una media estimada y una desviación estándar usando una metodología estándar. Por otro lado, como menciona el autor “Realizamos meta análisis en Stata 14(StataCorp, College Station, TX). Se utilizaron modelos de efectos aleatorios de DerSimonian-Laird para estimar las medias agrupadas y los intervalos de confianza del 95% para las diferentes dimensiones de la biometría CC y CSP por semana gestacional” [27]. Todo lo anterior les permitió generar una tabla donde se muestran los rangos de normalidad por semana, la cual incluye la media y desviación estándar

Aportes del documento al proyecto

Este artículo permite visualizar un problema que se presenta al no tener una estandarización de los protocolos de investigación y de las publicaciones para los rangos biométricos normales. Lo anterior permite entender que el proceso para la determinación de un rango aceptable no está claramente definido. Aunque brinda una llave para poder determinar la mejor manera de calcular la estructura Cavum Septi Pellucidum, la cual se presenta cuando el autor menciona “Aunque, en general, es suficiente visualizar un CSP de apariencia normal, ocasionalmente surge la necesidad de medir el CSP para garantizar la normalidad” [27], esta afirmación indica que es posible determinar una anomalía teniendo en cuenta la forma que posea la estructura.

Tercer Artículo

Abnormal shape of the cavum septi pellucidum: an indirect sign of partial agenesis of the corpus callosum

Tipo de documento	Artículo	Ref.Doc	[28]
-------------------	----------	---------	------

Descripción del documento

Dentro de este artículo se plantea un estudio que se realizó a 71 casos atendidos entre 2006 y 2014. Dentro del cual se diagnosticó una forma anormal del Cavum Septi Pellucidum o también denominado CSP, cuando su dimensión lateral era mayor que su dimensión anteroposterior en el plano Trans-thalamic. Como consecuencia se obtuvieron los siguientes resultados:

- En 56 casos fue posible medir el CSP.
- De los 56 casos medidos 19 de ellos presentaban una forma anormal.

- Y de los 19 anormales 15 de los casos no tenían signos indirectos de agnesia parcial del cuerpo calloso.
- De 23 casos con agnesia parcial del cuerpo calloso, 12 de ellos tenían un CSP anormal.

Todo este estudio fue llevado a cabo sobre datos obtenidos de dos centros hospitalarios los cuales fueron el Hospital Armand Trousseau en París, Francia y el Hospital Shaare Zedek en Jerusalén, Israel, todo este proceso se realizó con el objetivo de identificar y evaluar la presencia de un signo indirecto de agnesia parcial del cuerpo calloso teniendo en cuenta una forma anormal del CSP.

Forma de Identificar la anomalía de la estructura

Para el caso del estudio se consideró una forma anormal de la estructura cuando su longitud era menor que su ancho. Además, se tuvo en cuenta los siguientes aspectos:

- El CSP estuviera ausente o inmensamente pequeño.
- Tercer ventrículo anormalmente elevado.
- Mayor distancia entre los cuernos frontales de los ventrículos laterales.
- Configuración de lagrima.
- Agrandamiento de los ventrículos laterales.

Aportes del documento al proyecto

Para el proyecto, este artículo brindó una asociación directa de una forma anormal basada en el tamaño del CSP con la presencia de un defecto como lo es la agnesia parcial de cuerpo calloso. Lo anterior permite asociar un tamaño irregular de la estructura con el dictamen que se generó como parte del desarrollo del tercer objetivo específico del proyecto.

Cuarto Artículo

Transabdominal sonography of the Cavum septum Pellucidum in normal fetuses in the second and third trimester of pregnancy

Tipo de documento	Artículo	Ref.Doc	[29]
-------------------	----------	---------	------

Descripción del documento

Este artículo llevo a cabo un estudio de la forma Cavum Septum Pellucidum sobre el plano craneal Trans-Ventricular en cerca de 286 casos de embarazo sin complicaciones, como resultados del análisis llevado se determinó los siguientes hallazgos:

- La estructura Cavum Septum Pellucidum fue observada en el 40% de los casos a las 15 semanas, el 82% a las 16-17 semanas, el 100% a las 18-37 semanas y el 79% a las 38-41 semanas.
- En comparación con el diámetro biparietal (DBP), la tasa de visualización fue del 33% entre 31 y 32 mm, del 45% entre 33 y 34 mm, del 84% entre 35 y 43 mm, del 100% entre 44 y 88 mm y del 86% entre 89 y 99 mm.
- El ancho medio de la CSP fue de $5,3 \pm 1,7$ mm (rango de 2 a 9 mm).
- El ancho del Cavum Septum Pellucidum aumentó con la edad gestacional y la DBP, pero con una ligera disminución alrededor del término.

-
- El Cavum Septum Pellucidum no debe ser muy largo, esto puede inferir una anomalía dentro del desarrollo del feto.

Todo el anterior cálculo fue llevado a cabo tal y como se menciona en [29], “se midió su diámetro antero - posterior colocando la intersección de los marcadores de calibre en los bordes internos de su límite proximal y distal, respectivamente ('de adentro hacia adentro')”

Forma de Identificar la anomalía de la estructura

Para la identificación de la posible anomalía el proceso realizado por los autores determinó un rango de tamaño que correspondería a una posible anomalía dando como resultado que todo feto entre las semanas 18 y 37 debe poderse visualizar la estructura, además que el diámetro biparetal debería oscilar entre los 44 a 88 milímetros. El incumplimiento de las anteriores estipulaciones puede indicar un desarrollo cerebral anormal, por el contrario si la estructura no se encuentra antes de las 18 semanas o después de las 37, es un hallazgo normal.

Aportes del documento al proyecto

El artículo proporcionó un aporte importante al proyecto debido a que menciona con claridad dos posibles maneras de evaluar una anomalía:

- La primera forma para hallar la anomalía se basa en que este debe estar en un rango de 44 a 88 milímetros dentro de su diámetro biparetal, pero esto plantea un problema al no conocer como fueron tomadas las imágenes y si tuvieron algún proceso de manipulación al momento de la toma.
- En la segunda forma de identificación se tiene en cuenta el tamaño, y se determina que no debe existir un tamaño demasiado largo, esto debido a que puede inferir una anomalía en el crecimiento de la estructura.

La revisión sistemática que se llevó a cabo para determinar antecedentes en una posible forma de calcular una anomalía, fue realizada con documentos de los últimos 24 años, el objetivo de tener un amplio espacio de tiempo fue determinar si a lo largo de este lapso se ha determinado alguna forma para identificar un rango de normalidad en la estructura Cavum Septum Pellucidum. La revisión realizada indica que hasta el año de 2021 todavía no hay una buena forma para identificar los rangos que buscamos tal y como lo menciona Joshua I. Rosenbloom, Lauren H. Yaeger, y Shay Porat, en [27] esto debido a problemas por los procesos de estandarización y protocolos para la publicación de rangos de normalidad. Todo lo anterior conlleva a determinar que la mejor manera de obtener un rango normal surge de las siguientes dos posibilidades:

- Tomar una muestra de imágenes que sean consideradas normales y generar un valor de normalidad o anomalía de la estructura Cavum Septum Pellucidum.
- A pesar de la revisión sistemática no queda claro los rangos de anomalía, por lo que existe una fuerte aclaración en todos los artículos en donde se especifica que la forma es un claro indicador de una anomalía. Teniendo en cuenta lo anterior esta sería una manera fiable

sin tener en cuenta las medidas de la estructura y así obtener un concepto de normalidad o anormalidad.

Ahora se debe tener en cuenta que las imágenes del estudio fueron pre procesadas por procesos como Oversampling, Data Augmentation y redimensionamiento. Por lo que la mejor forma para obtener un posible diagnóstico es no centrarse en las medidas, esto debido a que los rangos mencionados son muy dispares a los que se posee en las imágenes del proyecto.

4 DESARROLLO DE MODELOS PARA LA IDENTIFICACION DEL PLANO CRANEAL Y ESTRUCTURA CAVUM SEPTUM PELLUCIDUM

Dentro del generación de este proyecto se tuvo la tarea de definir, desarrollar e implementar dos modelos, uno de ellos estuvo encargado de la clasificación del plano cerebral y el segundo modelo tuvo como objetivo principal la identificación de la estructura Cavum Septum Pellucidum. Adicionalmente se menciona que este proceso fue diseñado de una manera secuencial en donde cada tarea se llevó a cabo dentro de una etapa específica.

Las etapas que tuvimos para el desarrollo de los modelos fueron las siguientes:

- Entendimiento de la necesidad y motivaciones medicas del proyecto.
- Selección de Datos para análisis.
- Análisis de la información.
- Pre-procesamiento de Datos.
- Diseño de Modelo.
- Ajuste de Hiperparámetros.
- Implementación del modelo final.

Las tareas antes mencionadas se realizaron una o más veces dependiendo de las necesidades que se presentaron en cada uno de los modelos. Se puede observar la interacción y el flujo que se llevó a cabo para la generación de los modelos en la Figura 6 - Flujo de Proceso Desarrollo de Modelo la cual muestra el diagrama de flujo con cada etapa:

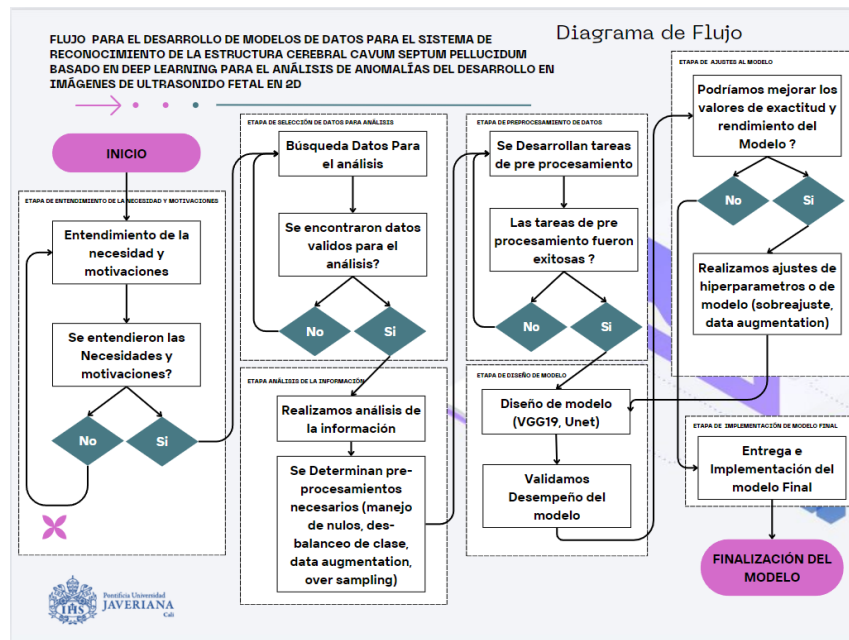


Figura 6 - Flujo de Proceso Desarrollo de Modelo

Flujo para el diseño e implementación de modelos de datos

A continuación, se ofrece una descripción de forma general cada una de las etapas y las tareas desarrolladas. Adicionalmente, la implementación detallada de cada una de dichas etapas, se realiza en los capítulos 5, 6 y 7, dónde se incluyen los resultados y su respectiva discusión.

4.1 Entendimiento de la necesidad y motivaciones medicas del proyecto

Dentro de esta etapa se profundiza en la comprensión de la necesidad básica del proyecto y cuáles son sus posibles impactos. Esta fase culmino de manera satisfactoria y se llegó a la conclusión de que la identificación de la estructura Cavum Septum Pellucidum es de crucial importancia debido a que una correcta identificación de una anomalía puede permitir la detección de enfermedades tales como holoprosencefalia, displasia septo-óptica, agenesia de cuerpo caloso, enfermedad de Alexander, esclerosis tuberosa, facomatosis, pinealoma, trisomía del par y esquiencefalia, las cuales podían ser tratadas antes de la gestación del niño o niña.

Como parte final de esta etapa se definió que la necesidad y motivación principal es: contribuir a mejorar la detección de alguna posible anomalía dentro del desarrollo del feto, esto debido a que la toma de los ultrasonidos y la detección de la estructura es un proceso manual, el cual está sujeto a posibles errores humanos. Con lo anterior se busca brindar un apoyo a los médicos y técnicos para realizar un proceso más eficiente, que les permita una toma de decisiones más sencilla y ágil.

4.2 Selección de Datos para análisis

La etapa de selección de datos para el análisis es de vital importancia debido a que permite adquirir

la información y máscaras necesarias para llevar a cabo el diseño, desarrollo e implementación de los modelos de datos. Para esto se determinó una serie de requisitos fundamentales que debería tener el dataset. Todos estos requisitos se encuentran explicados con detalle dentro del numeral 5.1 del presente documento.

4.3 Análisis de la información

Esta etapa permite obtener un análisis sobre un dataset que cuenta con 2.949 imágenes de ultrasonido de alta definición, las cuales están divididas en 1.638 para el plano cerebral Trans-thalamic, 714 para el plano Trans-Cerebellum y 597 para el plano Trans-ventricular, tal y como se muestra en la Figura 7 - Diagrama de Barras Plano Cerebral. Adicionalmente, se puede observar que hay un evidente desbalanceo de clases, por lo que se requirieron de algunas tareas de pre-procesamiento, las cuales fueron identificadas gracias a la etapa de selección.

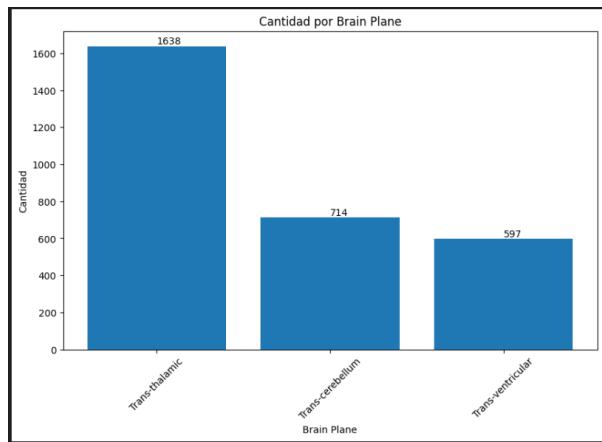


Figura 7 - Diagrama de Barras Plano Cerebral
Muestra la distribución de las imágenes del dataset por plano cerebral

Por otro lado, en esta etapa se llevaron a cabo tareas entre las cuales tenemos:

- Identificación de nulos.
- Visualización de imágenes.
- Identificación de calidad.
- Identificación de dimensiones de las imágenes.
- Identificación de canales.
- Identificación de tareas de pre-procesamiento.

Todos los anteriores procesos fueron necesarios como entrada para el pre-procesamiento de datos.

4.4 Pre-procesamiento de Datos

Para la realización de la etapa de pre-procesamiento de los modelos se tomó la determinación de llevar a cabo varios procesos para contar con aspectos tales como:

- Balanceo de clases
- Calidad de la información
- Cantidad de Imágenes

Teniendo en cuenta que el objetivo de esta etapa es contar con los anteriores aspectos, los principales procesos realizados a los datos fueron:

- **Proceso de Oversampling:** este paso permitió que todas las clases de las imágenes se pudieran balancear a un total de 2000 registros por clase.
- **Data Augmentation:** Este proceso permite generar nuevas imágenes a partir de la aplicación de transformaciones tales como rotaciones, traslaciones, escalado, reflejo o corte. Adicionalmente ayuda a mejorar los procesos de generalización, sobreajuste y escasez de imágenes que puede afectar a los diferentes modelos.
- **Redimensionamiento:** debido una serie de problemas computacionales y a temas de modelamiento, fue necesario el cambio de tamaño de las imágenes, esto permite a los modelos un consumo moderado de recursos computacionales y una entrada estándar para todos los modelos. Para este caso particular las dimensiones escogidas para las imágenes fueron de 224 por 224 pixeles de alto y ancho respectivamente.
- **Generación de Carpetas con Conjuntos de Entrenamiento y Pruebas:** Tanto para el modelo de Identificación de Planos Craneales como para la Identificación de la estructura Cavum Septum Pellucidum, se llevó a cabo la creación de carpetas las cuales contienen los conjuntos necesarios de entrenamiento y pruebas. Adicionalmente cada una de estas carpetas está diseñada de tal manera que sirvan como ingesta de los modelos que se desarrollaron a lo largo de este trabajo.

Para el caso del modelo de Clasificación de planos craneales se crearon carpetas con conjuntos de entrenamiento y pruebas, los cuales a su vez contenían subcarpetas de las tres opciones de plano craneal. Es decir, se contó con una carpeta para cada uno de los planos Trans-thalamic, Trans-Ventricular y Trans-Cerebellum. Por otro lado, para los diferentes modelos de identificación de la Estructura Cavum Septum Pellucidum, se dividieron primero en dos carpetas las cuales resguardaron las imágenes de los planos y las máscaras de cada imagen. Adicionalmente dentro de cada carpeta se encuentran cada uno de los planos cerebrales (Trans-thalamic, Trans-Ventricular y Trans-Cerebellum) y sus respectivos conjuntos de Entrenamiento y Prueba. Como dato adicional para cada caso, los conjuntos de datos de información fueron divididos en un 70% para entrenamiento del modelo y un 30% para pruebas.

4.5 Diseño de modelo

Para la tarea del diseño de cada uno de los modelos se optó por realizar en primera instancia el desarrollo de modelos básicos bajo las siguientes características:

- **Diseño básico de Modelo:** se decide tomar un modelo que cumpla con las necesidades básicas para el proceso de clasificación. Lo anterior proporciona ventajas tales como: complejidad del modelo baja, diagnóstico más sencillo, rapidez de iteración, consumo computacional moderado, además por último el modelo permite un aprendizaje y ajuste de manera incremental.
- **Aplicación de Transferencia de Aprendizaje:** para cada uno de los modelos aplicados se hizo uso del proceso de transferencia de conocimiento como parte para los procesos de entrenamiento.
- **Selección de Red Neuronal para el modelo:** para el caso del modelo de clasificación del plano cerebral se realiza una comparación entre 4 posibles redes neuronales. Los modelos analizados fueron Resnet50, Resnet101, VGG16 y VGG19. De las anteriores redes se seleccionó la que tuvo mejores métricas de accuracy. Adicionalmente para el otro modelo en el que se realizó la identificación de la estructura CSP se seleccionó una red convolucional U-net, la cual se realizó bajo una red neuronal VGG16 con congelamiento de pesos. Los principales motivos para esta elección fueron:
 - Vgg16 es más sencilla que otras redes, al tener menos capas profundas cuenta con menos parámetros y reduce el costo computacional.
 - Menor tiempo de entrenamiento esto debido a que poseemos un hardware limitado.
 - Se considera a la VGG16 lo suficientemente profunda para la tarea de identificación de la estructura Cavum Septum Pellucidum.

Todos los anteriores criterios permiten generar modelos de datos con unas muy buenas características para manejar los procesos de identificación del plano craneal y la identificación de la estructura CSP. Además de contar con aspectos tales como transferencia de conocimiento y calidad de información que a largo plazo generaron buenos resultados en las métricas de cada modelo.

4.6 Ajustes al Modelo

Para los procesos de ajustes de modelo, se llevó a cabo la búsqueda de los mejores Hiperparámetros con las funciones Randomsearch y HyperBand. Las principales razones para el uso de estas funciones de afinación son las siguientes:

Tabla 6 - Ventajas RandomSearch e HyperBand

RandomSearch
Ventajas
<p>Entre las ventajas del uso de RandomSearch se encuentran:</p> <ul style="list-style-type: none"> • Es fácil de entender y aplicar. • No asume una distribución específica de Hiperparámetros. • Mejor exploración de espacios grandes. • Ahorra tiempo y recursos, al usar de forma aleatoria las posibles mejores combinaciones. • Resultados eficientes con menos iteraciones. • Es uno de los más comúnmente usados.
HyperBand
Ventajas
<p>Entre las ventajas del uso de HyperBand se encuentran:</p> <ul style="list-style-type: none"> • Asigna dinámicamente recursos, esto conlleva a una reducción de costo computacional. • Permite un buen desempeño con espacios de alta dimensionalidad, obteniendo un buen balance entre velocidad y performance. • Es un algoritmo sofisticado de optimización de Hiperparámetros.

Los principales Hiperparámetros validados en los diferentes modelos fueron el dropout, learning rate, filters, capas y cantidad de neuronas. Por otro lado, como última tarea se compararon los resultados obtenidos del modelo ajustado en contra de los resultados obtenidos con el modelo original para ver si existe mejoría. En casi todos los modelos se obtuvo mejoras significativas, aunque en algunos la mejora se encuentra por debajo de 1%. Se entiende que este proceso podría mejorarse, pero por temas de tiempo se limitó el proceso para ser llevado en un lapso de 2 semanas. Esto estableció un límite a los procesos de ajuste, además de delimitar una entrega del modelo final que cumpla con unas características válidas para el proyecto.

4.7 Implementación de modelo final

Dentro de la última tarea se realizó la implementación de los resultados obtenidos en la tarea de ajuste y se validó las mejoras que se obtuvo en cada modelo. Como parte adicional de este último paso, en el caso de los modelos de U-Net para la detección de la estructura Cavum Septum Pellucidum, se creó una estructura de carpetas donde se tomaron 10 imágenes de prueba por cada modelo y se calculó las máscaras predichas, estos archivos sirvieron como parte esencial para el proceso del tercer objetivo específico donde se determina dos posibles caminos para la generación de un dictamen de normalidad u anormalidad. El primero de ellos se define teniendo en cuenta la forma (ancho y alto) de la estructura identificada y el segundo camino se define teniendo en cuenta las recomendaciones un obstetra profesional sobre la conformación del dataset.

5 SELECCIÓN DE CRITERIOS DE RECOLECCIÓN Y PROCESAMIENTO DE LAS IMÁGENES DE ULTRASONIDO FETAL EN 2D.

Para el desarrollo del primer objetivo se realizó una serie de tareas que colaboraron en la identificación, análisis y entendimiento de los datos que fueron ingresados posteriormente a los modelos. Estas tareas fueron las siguientes:

5.1 Identificar y Establecer las características adecuadas para las imágenes

Para el desarrollo del primer objetivo, en primera instancia se fijaron una serie de parámetros para la adquisición de imágenes de ultrasonido fetal, estos parámetros fueron los siguientes:

- Las imágenes seleccionadas para el análisis corresponderán a ultrasonido en 2D.
- Las imágenes solo abarcaran planos del cerebro del feto.
- Solo se tendrán en cuenta ultrasonidos realizados a fetos entre las 11 y 36 semanas, lo cual corresponde al periodo de control prenatal realizado por los doctores.
- Solo se realizará análisis sobre la estructura craneal Cavum Septum Pellucidum, cualquier otra estructura craneal podría ser analizada para futuros trabajos.
- La base de imágenes seleccionadas cuenta con la suficiente cantidad de imágenes para el entrenamiento de los algoritmos.
- Se realiza un proceso de clasificación manual de las imágenes, lo que permite determinar la verdad absoluta. Este proceso fue llevado a cabo por parte de expertos en el tema prenatal.

Todas las imágenes deben cumplir con los parámetros especificados, esto se determinó para poder obtener datos que permitan su manipulación y manejo de la mejor manera, además que se asegura una reducción en temas tales como ruido o imágenes que no aplican para este proyecto. Estas características fueron evaluadas en conjunto con un experto en el área de la obstetricia y el tutor asignado, con los cuales se llegó a la conclusión que eran suficientes para obtener el conjunto de datos más adecuado al propósito del proyecto.

5.2 Búsqueda de bases de datos de imágenes de ultrasonido

Para el desarrollo de esta actividad se realizaron dos búsquedas en diferentes orígenes y además se validó si las imágenes encontradas cumplían con las características adecuadas para ser tenidas en cuenta dentro del proyecto, estas tareas fueron las siguientes:

5.2.1 búsqueda de bases de datos de imágenes

En el desarrollo de esta tarea se realiza una búsqueda en internet para identificar cuáles eran los bancos de imágenes más utilizados en el entorno médico, dentro los cuales se identifica a Shutterstock, Getty Images, iStock, Scienesource, National Library of Medicine, entre otros. Pero estas

presentaban problemas tales como dificultad para la selección de la imagen, costos, licencias y selección de imágenes muy amplia. Teniendo en cuenta lo anterior no se opta por seleccionar una base de datos de estos bancos debido a que el proceso de inspección y selección de las imágenes nos podría conllevar temas como costos y una alta dedicación de tiempo.

5.2.2 búsqueda de bases de datos usadas en otros trabajos de investigación

Dentro de este proyecto se realiza una revisión sistemática para determinar si existían antecedentes de otros proyectos parecidos. Para esto se usó bases o editoriales digitales tales como Ebsco, Springer o ScienceDirect y donde se constató que hay bases de datos libres que ya tienen meta data muy bien estructurada, las cuales han sido utilizadas como base de estudio por otros proyectos. Las dos tareas anteriores fueron llevadas a cabo durante un lapso de tiempo prudente, tratando de analizar cada uno de los pros y contras que cada uno de los orígenes de las imágenes podían acarrear.

5.3 Selección del conjunto de imágenes o base de datos

Como siguiente tarea que se lleva a cabo en este primer objetivo se determina que el mejor conjunto de datos para la realización de este proyecto proviene de las bases de datos ya usadas por otros trabajos de investigación, esto debido a que cumplen con el etiquetado, tipos de imágenes y licencias. Teniendo en cuenta todo lo mencionado anteriormente se selecciona la base de datos que se encuentra en la url: <https://zenodo.org/records/3904280>

Esto debido a que cumple con todas las características para el análisis de las imágenes. En la siguiente tabla podemos observar el estudio y las conclusiones que se obtuvieron al analizar el dataset seleccionado:

Tabla 7 - Criterios de selección de imágenes

Parámetro	Descripción	Cumple o no cumple
Las imágenes seleccionadas para el análisis corresponderán a ultrasonido en 2D.	Se valida la información que contiene el dataset y se confirma que corresponde a imágenes de ultrasonidos en 2D, tal y como se muestra en la Figura 8 - Imágenes de muestra Ultrasonido	Cumple
Las imágenes solo abarcaran planos del cerebro del feto.	Se realiza una validación y la data está dividida en diferentes planos del cerebro fetal, además de otros que no están asociados con el objetivo de este proyecto.	Cumple
Solo se tendrán en cuenta ultrasonidos realizados a fetos entre las 11 y 36 semanas, lo cual corresponde al periodo de control	Se realiza la validación y según la información proporcionada para el dataset, este grupo de imágenes corresponde a ecográficas de detección materno-fetal adquiridas en dos hospitales	Cumple

prenatal realizado por los doctores.	diferentes por varios operadores y las cuales fueron etiquetadas por un experto. Lo anterior garantiza que las imágenes corresponden a seguimientos maternos realizados a los fetos entre el periodo que deseamos analizar.	
Solo se realizará análisis sobre la estructura craneal Cavum Septum Pellucidum, cualquier otra estructura craneal podría ser analizada para futuros trabajos.	Se valida y dentro de la información del dataset se encuentran imágenes que contienen la estructura Cavum Septum Pellucidum.	Cumple
La base de imágenes seleccionadas contara con la suficiente cantidad de imágenes para el entrenamiento de los algoritmos.	Se valida y el dataset cuenta con 12.400 imágenes de ultrasonidos, pero de este grupo solo nos quedaremos con 2.949 que corresponden a los tres planos craneales del feto.	Cumple
Se realizará un proceso de clasificación manual de las imágenes, lo que nos permitirá determinar la verdad absoluta. Este proceso se realizará con ayuda de expertos en el tema prenatal	Se valida y el dataset contiene además de las imágenes un archivo de Excel llamado "FETAL_PLANES_DB_data.csv" el cual contiene una detallada información de meta data.	Cumple

5.4 Resumen de las actividades

Como último aporte relacionaremos un pequeño resumen donde se incluye las conclusiones obtenidas de las actividades programadas para el primer objetivo:

Tabla 8 - Resumen de resultados Primer Objetivo

Tarea: Establecer las características adecuadas para la selección de imágenes

Las imágenes contienen las características mínimas especificadas dentro del capítulo 5.1 para Identificar y Establecer las especificaciones adecuadas para las imágenes

Tarea: Realizar búsqueda de bases de datos de imágenes de ultrasonido con los criterios establecidos

Se exploraron diversas fuentes para obtener imágenes de ultrasonido 2D, incluyendo contactos en el sector salud e internet, pero se encontraron varias dificultades, tales como: los hospitales requieren un proceso burocrático que podría retrasar el proyecto o las imágenes en línea no siempre son adecuadas ni están etiquetadas correctamente. Teniendo en cuenta lo anterior y tras revisar artículos, se identificó una base de datos en Zenodo la cual cumplía con los requerimientos por lo que se decidió utilizarla como la principal para el proyecto de grado

Tarea: Seleccionar conjunto de imágenes

Debido a que la base de datos de Zenodo cumple con las características establecidas para el proceso, se determina que esta será la base de datos utilizada para el proceso de modelamiento.

Estas actividades fueron desarrolladas para dar alcance al primer objetivo específico del proyecto y finalizaron de manera exitosa.

6 IMPLEMENTACIÓN DE MODELOS DE APRENDIZAJE DE MÁQUINA PARA LA IDENTIFICACIÓN AUTOMÁTICA DEL PLANO CEREBRAL Y EL RECONOCIMIENTO DEL CAVUM SEPTUM PELLUCIDUM

Dentro del desarrollo de las tareas que se realizan para el segundo objetivo específico se llevó a cabo los siguientes puntos.

6.1 Revisión del estado del arte

Dentro de las tareas de revisión del estado del arte se realizaron investigaciones sobre algunos temas para poder desarrollar cada una de los ítems necesarios. Los temas investigados son los siguientes:

- Estudio y entendimiento de las librerías keras y openCV para el manejo de imágenes.
- Estudio y entendimiento de tensorflow para el manejo de redes neuronales convolucionales.
- Estudio y entendimiento de Redes Neuronales profundas Resnet, VGG y Unet.
- Entendimiento del código necesario en Python para la aplicación de las redes neuronales.

Todas las investigaciones fueron llevadas a cabo dentro de google y la biblioteca de la universidad.

6.2 Construcción del conjunto de Datos

Para llevar a cabo la construcción del conjunto de datos que se utiliza como base para el entrenamiento y pruebas del modelo para la identificación de la estructura o el plano cerebral, se realiza una serie de procesos los cuales permitieron llegar a un dataset balanceado con buenas características para el entrenamiento del modelo. Las tareas para la generación del conjunto de datos fueron las siguientes:

6.2.1 Análisis Exploratorio de la información

Como primer paso para la generación del conjunto de datos adecuado para el entrenamiento y pruebas, se realiza un proceso exploratorio de la información para determinar temas como datos faltantes, desbalanceo de clases y eliminación de datos no útiles para el proceso.

En primera instancia se lleva a cabo una identificación de las imágenes en donde se visualizó que existieran ultrasonidos en 2D, para lo cual se implementa la librería OpenCV y se genera una serie de imágenes que garantizo que el conjunto de datos contiene el tipo de archivos adecuado a ser analizadas, un ejemplo de los archivos encontrados puede ser visualizados en la Figura 8 - Imágenes de muestra Ultrasonido




Figura 8 - Imágenes de muestra Ultrasonido

Imágenes de Ultrasonido contenidas en el dataset

Teniendo en cuenta que existían datos de ultrasonidos, se debe garantizar que estas imágenes pertenezcan a planos cerebrales de fetos por lo que se procede a cargar y cruzar la meta data que tiene el dataset en el archivo de Excel llamado “Fetal: planes_DB: data.csv”, con lo que se obtuvo una clasificación más completa de los planos cerebrales, esta información fue guardada en un dataframe para una mejor manipulación. A continuación, se puede observar una muestra del dataframe en la siguiente Figura 9 - Dataset

El DataFrame tiene 12400 registros.

	Imagen	Tamaño	NombreLimpio	Patient_num	Plane	Brain_plane	Operator	US_Machine	Train
0	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(382, 649)	Patient00001_Plane1_10_of_15	1	Other	Not A Brain	Other	Aloka	1
1	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(386, 645)	Patient00001_Plane1_11_of_15	1	Other	Not A Brain	Other	Aloka	1
2	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(424, 687)	Patient00001_Plane1_12_of_15	1	Other	Not A Brain	Other	Aloka	1
3	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(425, 688)	Patient00001_Plane1_13_of_15	1	Other	Not A Brain	Other	Aloka	1
4	[[[54, 51, 47], [42, 41, 37], [34, 33, 29], [2...	(378, 560)	Patient00001_Plane1_14_of_15	1	Other	Not A Brain	Other	Aloka	1
5	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(381, 647)	Patient00001_Plane1_15_of_15	1	Other	Not A Brain	Other	Aloka	1
6	[[[0, 0, 0], [0, 0, 0], [45, 44, 40], [52, 49, ...	(377, 648)	Patient00001_Plane1_1_of_15	1	Other	Not A Brain	Other	Aloka	1
7	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(383, 650)	Patient00001_Plane1_2_of_15	1	Other	Not A Brain	Other	Aloka	1
8	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(381, 647)	Patient00001_Plane1_3_of_15	1	Other	Not A Brain	Other	Aloka	1
9	[[[0, 0, 0], [0, 0, 0], [0, 0, 0], [0, 0, 0], ...	(381, 647)	Patient00001_Plane1_4_of_15	1	Other	Not A Brain	Other	Aloka	1

Figura 9 - Dataset

Dataset con metada cargado en Python

Por otro lado, al momento de cruzar la meta data con las imágenes se pudo verificar dos aspectos, el primero fue que la meta data estaba completa y contenía información importante para el análisis. el segundo aspecto validado fue que no existían datos nulos y que toda la data se encuentra completa, por lo que el problema de datos faltantes no requiere un pre-procesamiento. Luego se procedió a verificar la distribución de los planos cerebrales y se certifica que la data cuenta con imágenes de cráneos fetales, dando como resultado que los 12.400 registros totales de la

información se encuentran distribuidos de la siguiente forma:

Tabla 9 - Distribución de Imágenes por Plano cerebral

Brain Plane	Cantidad
Not a Brain	9.308
Trans-thalamic	1.638
Trans-Cerebellum	714
Trans-Ventricular	597
Otros	143
Total	12.400

La anterior permite evidenciar que se debió realizar una tarea de filtrado lo que nos permite eliminar los datos que no correspondieran a planos cerebrales y obtener la distribución final de los datos final de la siguiente manera:




Figura 10 - Diagrama de barras Distribución de planos cerebrales

Distribución de imágenes que corresponden a planos cerebrales

Este escenario plantea un desbalanceo de clases que fue tratado antes de generar el conjunto de datos. Adicionalmente se valida que las imágenes correspondan a planos craneales del feto, tal y como se puede observar en la imagen de la Figura 11 - Ultrasonido Craneal:




Figura 11 - Ultrasonido Craneal

Muestra de una imagen de ultrasonido 2D craneal

Un dato interesante obtenido dentro del análisis de estas imágenes fue que tiene 3 canales, lo que indica el uso de RGB y una resolución de (392x640) pixeles, por lo cual también se procede a validar el tamaño de las imágenes y su calidad. En la siguiente tabla y figuras se puede observar la distribución de la resolución de las imágenes por plano cerebral:

Tabla 10 - Distribución de imágenes por tamaño

Brain Plane	Cantidad	Menor resolución	Mayor resolución	distribución
Trans-thalamic	1.638	(392,640)	(787,1495)	Ver Figura 12 - Diagrama de Barras
Trans-Cerebellum	714	(392,640)	(787,1495)	Ver Figura 13 - Diagrama de Barras
Trans-Ventricular	597	(392,640)	(787,1137)	Ver Figura 14 - Diagrama de Barras
Total	2.949			

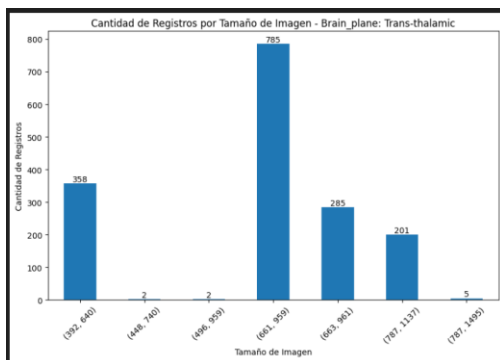


Figura 12 - Diagrama de Barras Trans-Thalamic

Distribución del plano Trans-Thalamic por tamaño de imágenes

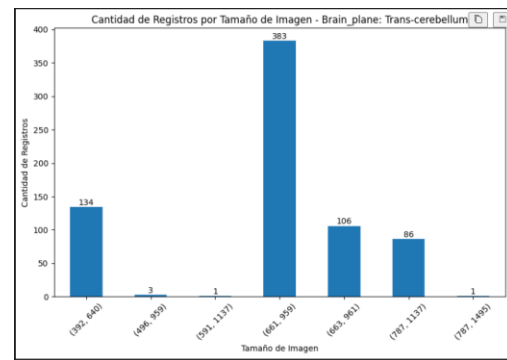


Figura 13 - Diagrama de Barras Trans-Cerebellum

Distribución del plano Trans-Cerebellum por tamaño de imágenes




Figura 14 - Diagrama de Barras Trans-Ventricular

Distribución del plano Trans-Ventricular por tamaño de imágenes

Esto permite indicar que otro de los procesos que a realizar dentro de los datos es un proceso de redimensionamiento, esto debido a que todas las imágenes que ingresan a los modelos deben poseer exactamente la misma dimensión.

Todos los procesos anteriormente realizados sobre la información llevaron a la conclusión que se debería realizar las siguientes tareas de pre-procesamiento antes de generar el conjunto de datos:

- Selección de datos relevantes para el análisis (solo planos cerebrales, esta tarea se realizó en esta etapa debido a su simplicidad).
- Redimensionamiento de imágenes.
- Balanceo de Clases.
- Generación de nuevas imágenes por medio de la técnica Data Augmentation.

Estas tareas serán explicadas en el siguiente numeral.

6.2.2 Pre-procesamiento y Selección de la información

En esta tarea se procede a realizar los pre-procesamientos necesarios para la generación del conjunto de pruebas y entrenamiento, en primer lugar, como se podido a observar, las imágenes presentan diferentes dimensiones, lo que hace necesario un proceso de redimensionamiento para que puedan ser analizadas correctamente por el modelo. Debido a lo anterior, se toma la decisión de ajustar las imágenes a una resolución de 224 x 224 píxeles, lo que facilita su manejo y procesamiento. En la Figura 15 - Ultrasonido Craneal se puede apreciar el resultado de una imagen después de ser redimensionada.



Figura 15 - Ultrasonido Craneal

Imagen de ultrasonido craneal redimensionada a 224x224

Para tratar el tema del desbalanceo, se implementan dos procesos. En el primero de ellos se realiza un Oversampling, dentro del cual se seleccionan datos al azar y se replica la información para obtener un total de 2.000 registros por cada clase. Lo anterior permite que el conjunto de datos pase de 2.949 imágenes a un total de 6.000. Esto se puede observar en la nueva distribución de las clases dentro de la Figura 16 - Diagrama de Barras:

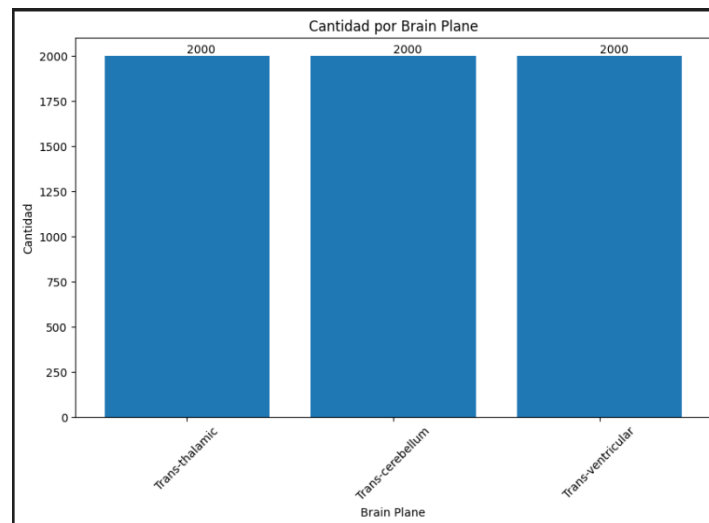


Figura 16 - Diagrama de Barras Balanceo de Oversampling

Distribución de imágenes luego de Oversampling

Pero los datos duplicados contienen exactamente las mismas imágenes que ya se tienen anteriormente, por lo cual se aplica un segundo proceso donde se realiza un Data Augmentation. Esta técnica permite tomar la imagen original que se encuentra duplicada y modificarla por medio de tareas de transformación tales como traslación, rotación, ajuste de nitidez, cambio de Angulo, entre otros, lo que genera una nueva imagen y hace que el modelo sea más resistente a cambios en los ultrasonidos. Una muestra de las imágenes resultantes luego de finalizado el proceso se puede

observar en la Figura 17 - Imágenes de Ultrasonidos artificiales:




Figura 17 - Imágenes de Ultrasonidos artificiales
Imágenes luego de la aplicación del Data Augmentation

6.2.3 Construcción de carpetas con el conjunto de datos

Como último paso y luego de haberse llevado a cabo los procesos de pre-procesamiento se dividió el dataset modificado en carpetas con la siguiente estructura:

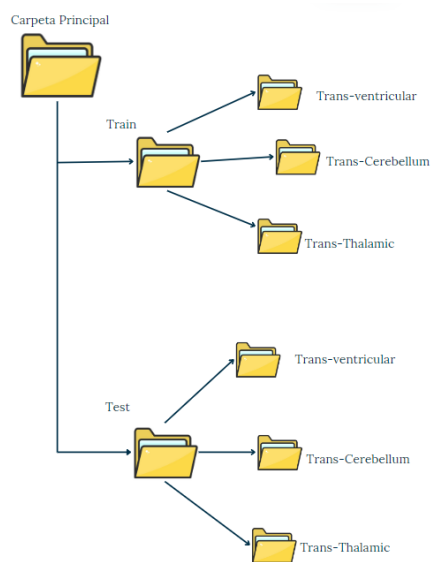


Figura 18 - Distribución de carpetas
Carpetas creadas para los conjuntos de entrenamiento y prueba

Por último, se determina una distribución de un 70% de la data para entrenamiento y 30% para

pruebas dando como resultado final un total de 4200 imágenes para entrenamiento y 1800 imágenes para Pruebas. Estos a su vez se dividieron en las tres categorías de los planos craneales (Trans-thalamic, Trans-ventricular y Trans-Cerebellum), dando como resultado la siguiente distribución en cada una de las carpetas:

Tabla 11 - Cantidad de Imágenes para entrenamiento y prueba

Carpeta Principal	Sub Carpeta por categoría	Cantidad Muestra Imágenes	
Train			
	Trans-thalamic	1.400	Esta carpeta es la que contiene de las imágenes de plano Trans-thalamic
	Trans-Cerebellum	1.400	Esta carpeta es la que contiene de las imágenes del plano Trans-Cerebellum
	Trans-ventricular	1.400	Esta carpeta es la que contiene de las imágenes del plano Trans-ventricular
Total		4.200	
Carpeta Principal	Sub Carpeta por categoría	Cantidad muestra Imágenes	
Test			
	Trans-thalamic	600	Esta carpeta es la que contiene de las imágenes de prueba para el plano Trans-thalamic
	Trans-Cerebellum	600	Esta carpeta es la que contiene de las imágenes de prueba para el plano Trans-Cerebellum
	Trans-ventricular	600	Esta carpeta es la que contiene de las imágenes de prueba para el plano Trans-ventricular
Total		1.800	

Todos los procesos de análisis, pre-procesamiento y creación de conjuntos de los datos para los modelos que se llevaron a cabo en este capítulo fueron implementados en Python y ejecutados usando Visual Studio Code. El código puede ser visualizado dentro del siguiente Anexo:

Anexo A - 001 - [Proyecto de Grado- Primer Modelo Clasificación de Planos](#)

El anterior documento proporciona una mayor claridad respecto a cómo se generaron los resultados anteriormente mencionados.

6.3 Definición e implementación de modelo de aprendizaje supervisado

Para seleccionar el modelo de clasificación de los planos cerebrales, se decidió utilizar dos redes neuronales: la primera, una ResNet y la segunda es una VGG, las razones para la selección de estas redes neuronales fueron las siguientes:

1. Se selecciona una ResNet debido a que, dentro de la revisión sistemática realizada, se identificó que esta era una de las redes neuronales que con mejor comportamiento y desempeño en el manejo de imágenes médicas.
2. Otra de las razones para seleccionar una ResNet es debido a que su aprendizaje residual permite entrenar redes aún más profundas, y por consiguiente se evita los problemas de desvanecimiento de la gradiente, además que permite el entrenamiento de modelos más profundos y precisos.
3. Debido a la limitada capacidad computacional, se opta por una red convolucional ResNet, la cual ha demostrado eficiencia en estos aspectos.
4. Se reconoce que la Resnet posee una serie de inconvenientes, tales como complejidad en la arquitectura (esto debido a sus bloques residuales), lo que puede hacerla un poco más difícil de entender y de implementar en comparación a otras redes convolucionales, o a la cantidad de memoria que podría requerir. No obstante, se considera que es una buena opción a tener en cuenta por los motivos anteriormente mencionados.

Por otro lado, las redes Convolucionales VGG16 y VGG19 presentan una serie de ventajas que se establecieron como relevantes para este tipo de proyecto, las cuales son:

1. Las redes VGG son relativamente de fácil y simple entendimiento, lo cual es adecuado debido a que el equipo de trabajo está conformado por personas que apenas comienzan el camino como Data Scientist.
2. Tal y como se especificó dentro de la maestría en Ciencia de datos, dos de los aspectos más importantes dentro de un modelo de red neuronal convolucional son los procesos de transferencia de aprendizaje y Data Augmentation. Teniendo en cuenta lo anterior es aquí donde las VGG cobran gran importancia debido a que las capas han demostrado ser útiles en la transferencia de aprendizaje en varias tareas de visión por computadora.
3. Asimismo, las VGG han demostrado un rendimiento en tareas de clasificación de imágenes. Aunque se reconoce que las VGG presentan una serie de desventajas tales como un alto consumo computacional (aspecto que no se posee) o una propensión hacia el sobre ajuste.

Teniendo en cuenta lo anterior se evaluaron 4 posibles modelos. Los modelos seleccionados fueron los siguientes:

- Restnet 50
- Resnet 101
- VGG 16
- VGG19

Para este proceso se define una estructura básica de red neuronal, la cual se implementa para todos los modelos y además contiene las siguientes capas:

- Primero se tiene una capa de transferencia de aprendizaje.


- Segundo se posee una capa de flatten, que se encarga de transformar las matrices multidimensionales resultantes de las capas convolucionales en un vector unidimensional.
- Tercero se tiene una capa densa activada con una función relu.
- Como cuarta capa un Dropout que colaborara con el sobreajuste del modelo.
- Por último, se tiene una capa de salida con 3 categorías y una función de activación softmax.

Luego de generada la estructura estándar la cual se aplica a todos los modelos, se lleva a cabo un entrenamiento y evaluación de cada uno de ellos. Los resultados finales de cada proceso se pueden visualizar en las siguientes Tablas:

Tabla 12 - Estadísticas Modelo Resnet 50

Modelo	Val_loss	Val_accuracy	Precisión	Recall	F1_score
Resnet 50	0.225895	0.915	0.91708	0.916111	0.916409

Matriz de confusión – Figura 19 - Matriz De Confusión Graficas de entrenamiento y validación - Figura 20 - Graficas de entrenamiento y validación



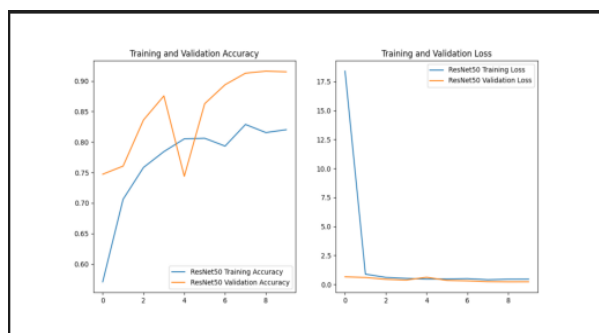
Explicación Matriz de Confusión

La matriz de confusión nos presenta una relación entre valores de la siguiente manera:

- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

Como se puede observar se tiene una gran coincidencia de verdaderos positivos pero también existen errores a niveles de Trans-thalamic categorizado como Trans-ventricular, por lo que más adelante, se seleccionó el mejor modelo y posteriormente se mejoró con la aplicación de Hiperparámetros.

Figura 19 - Matriz De Confusión Modelo Resnet50
Matriz de confusión Resnet 50



Explicación Graficas

Para este caso presentamos dos graficas en las cuales encontramos los siguientes hallazgos:

Grafica de accuracy: se puede observar que no tiene el mejor desempeño, para el caso de los datos de entrenamiento es constante, y para el caso de los datos de validación se presenta una caída en las épocas 3 y 4 lo que indica que el modelo está sobre ajustando los datos de entrenamiento y no está generalizando bien.

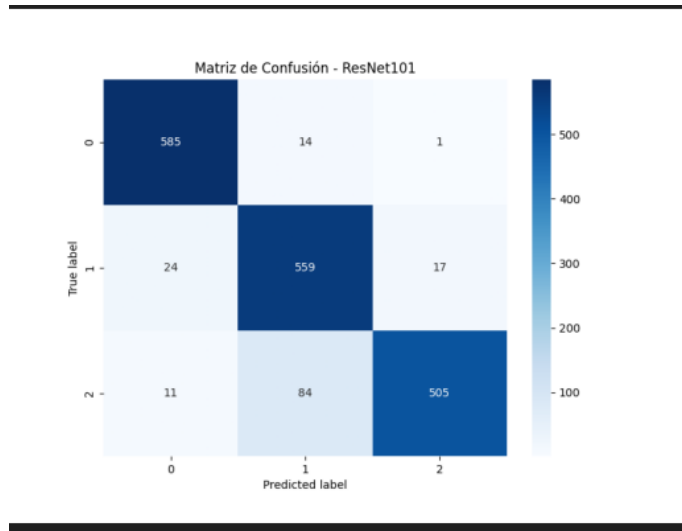
Grafica de Loss: se puede observar un pequeño sobre ajuste en la época 4, pero es muy pequeña la diferencia, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Figura 20 - Graficas de entrenamiento y validación Modelo Resnet 50

Grafica de entrenamiento y validación Resnet 50

Tabla 13 - Estadísticas Modelo Resnet 101

Modelo	Val_loss	Val_accuracy	Precisión	Recall	F1_score
Resnet 101	0.247285	0.899444	0.91999	0.916111	0.915937
Matriz de confusión - Figura 21 - Matriz de Confusión			Gráficas de entrenamiento y validación -Figura 22 - Graficas de entrenamiento y validación		



Explicación Matriz de Confusión

La matriz de confusión se presenta una relación entre valores de la siguiente manera:

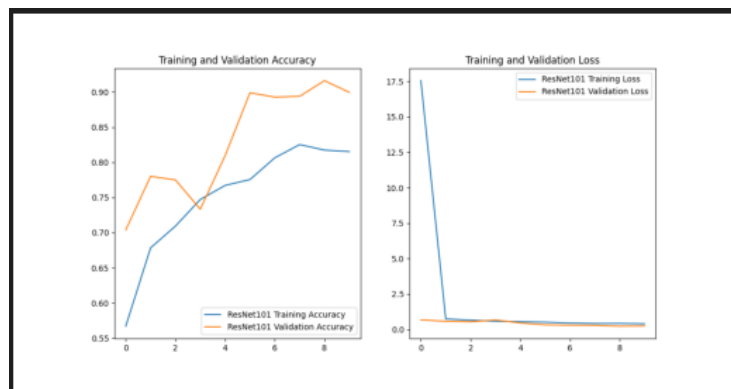
- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

se puede observar que se posee una gran coincidencia de verdaderos positivos, pero también se presentan errores a niveles de Trans- ventricular categorizado como Trans-thalamic, por lo que más adelante se seleccionó el mejor modelo y se procedió a mejorarlo.

Otro aspecto que se puede observar en este modelo, es que posee una mejor clasificación que el modelo de Resnet 50 anterior.

Figura 21 - Matriz de Confusión Modelo Resnet 101

Matriz de confusión Resnet 101



Explicación Graficas

Para este caso se presentan dos graficas en las cuales se exponen los siguientes hallazgos:

Grafica de accuracy: se puede observar que no tiene el mejor desempeño, en otras palabras, para el caso de los datos de entrenamiento es constante, pero en el caso de los datos de validación baja desde la época 1 hasta la 3 lo que indica que el modelo está sobre ajustando los datos de entrenamiento y no está generalizando bien. Pero presenta un menor sobreajuste que el anterior modelo.


Grafica de Loss: se puede observar un pequeño sobre ajuste en la época 3, pero es muy pequeña la diferencia, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Figura 22 - Graficas de entrenamiento y validación Modelo Resnet 101

Graficas de entrenamiento y validación Resnet 101

Tabla 14 - Estadísticas Modelo VGG16

Modelo	Val_loss	Val_accuracy	Precisión	Recall	F1_score
Vgg16	0.135098	0.948889	0.954687	0.948889	0.949481
Matriz de confusión Figura 23 - Matriz de confusión			Gráficas de entrenamiento y validación - Figura 24 - Graficas de entrenamiento y validación		



Explicación Matriz de Confusión

La matriz de confusión presenta una relación entre valores de la siguiente manera:

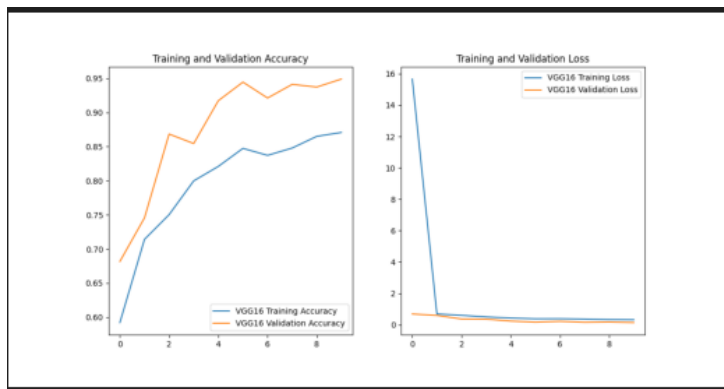
- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

Como se puede observar se tiene una gran coincidencia de verdaderos positivos, pero también presenta errores a niveles de Trans-ventricular categorizado como Trans-thalamic, por lo que más adelante se seleccionó el mejor modelo y posteriormente se mejoró.

Otro aspecto que se puede observar en este modelo, es que posee una mejor clasificación que los anteriores modelos.

Figura 23 - Matriz de confusión Modelo VGG16

Matriz de confusión VGG16



Explicación Graficas

Para este caso se presentan dos graficas en las cuales se exponen los siguientes hallazgos:

Grafica de accuracy: se puede observar que no tiene el mejor desempeño, en otras palabras, para el caso de los datos de entrenamiento es constante, pero en el caso de los datos de validación baja en dos épocas (3 y 6) lo que indica que el modelo está sobre ajustando los datos de entrenamiento y no está generalizando bien. Pero presenta un menor sobreajuste que los anteriores modelos.

Grafica de Loss: se puede observar que no posee curvas superiores a la data de entrenamiento, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Figura 24 - Graficas de entrenamiento y validación Modelo VGG16

Graficas de entrenamiento y validación VGG16

Tabla 15 - Estadísticas Modelo VGG19

Modelo	Val_loss	Val_accuracy	Precisión	Recall	F1_score
Vgg19	0.131184	0.96	0.961476	0.96	0.960019

Matriz de confusión - Figura 25 - Matriz de confusión Graficas de entrenamiento y validación - Figura 26 - Graficas de entrenamiento y validación

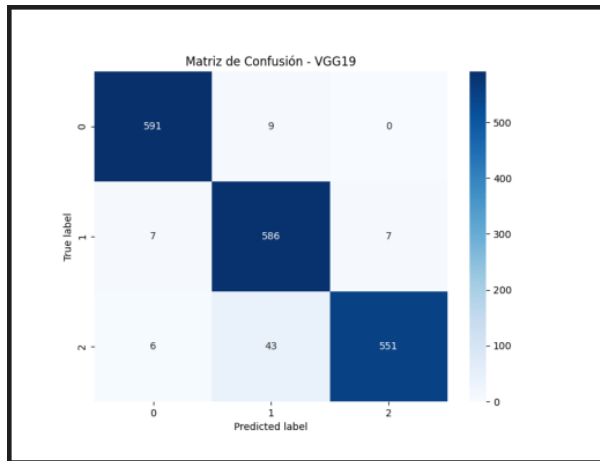


Figura 25 - Matriz de confusión Modelo VGG19

Matriz de confusión VGG19

Explicación Matriz de Confusión

La matriz de confusión presenta una relación entre valores de la siguiente manera:

- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

se puede observar que se tiene una gran coincidencia de verdaderos positivos, pero también existen errores a niveles de Trans-ventricular categorizado como Trans-thalamic, por lo que más adelante se selecciona el mejor modelo y posteriormente se mejora. Para este punto se llega al caso donde los falsos positivos y falsos negativos son menores a dos cifras y solo se visualiza un valor alto en caso de Trans-ventricular categorizado como Trans-thalamic. Otro aspecto que se puede observar en este modelo, es que se tiene una mejor clasificación que los anteriores modelos.

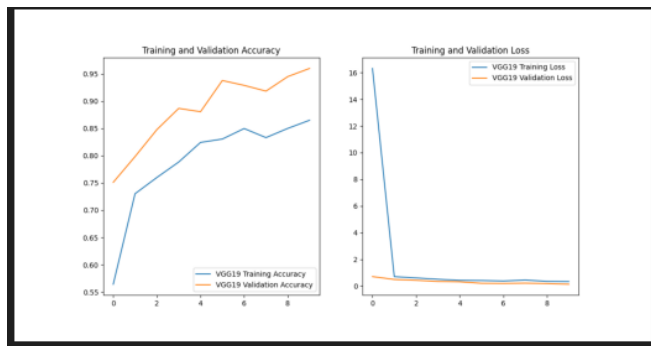


Figura 26 - Graficas de entrenamiento y validación Modelo VGG19

Graficas de entrenamiento y validación VGG19

Explicación Graficas

Para este caso se presentan dos graficas en las cuales se identifican los siguientes hallazgos:

Grafica de accuracy: se puede observar que no tiene el mejor desempeño, en otras palabras, para el caso de los datos de entrenamiento es constante, pero en el caso de los datos de validación baja en dos épocas (4 y 7) lo que indica que el modelo está sobre ajustando los datos de entrenamiento y no está generalizando bien. Pero presenta un menor sobreajuste que los anteriores modelos.

Grafica de Loss: se puede observar que no posee curvas superiores a la data de entrenamiento, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Por último, se presenta una gráfica de comparación entre todos los modelos, la cual puede ser visualizada en la siguiente imagen:




Figura 27 - Grafica de Comportamiento de Todos Los Modelos (Resnet50, Resnet101, VGG16 y VGG19)

Comportamiento de los modelos Resnet50, Resnet101, VGG16 y VGG19

Explicación Grafica

Dentro de la gráfica se muestran las curvas de accuracy y loss de todos los modelos validados para el proceso de clasificación. En total fueron 4 posibles modelos los validados para llegar a la conclusión que el mejor modelo para el proceso de identificación del plano craneal es el VGG19

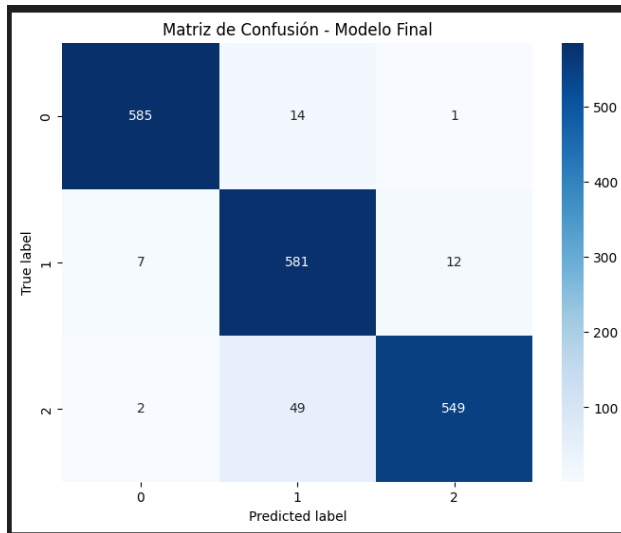
Como se puede observar el mejor modelo y al cual se le realiza validaciones o mejoras es el VGG19 esto debido a que contiene los mejores valores de accuracy (96%), precisión (96.1%) y recall (96%).

6.4 Tareas de Validación y Ajuste del modelo seleccionado

Luego de determinar cuál es el modelo que tuvo mejor desempeño se decide ejecutarlo de manera individual para ver el comportamiento, obteniendo los siguientes resultados:

Tabla 16 - Estadísticas Modelo VGG19 - Segunda Ejecución

Modelo	Val_accuracy	Precisión	Recall	F1_score
Vgg19	0.95	0.98	0.97	0.98
Matriz de confusión	Gráficas de entrenamiento y validación			
Figura 28 - Matriz de confusión	Figura 29- Gráficas de entrenamiento y validación			
Valores de rendimiento - Figura 30	Valores de rendimiento			



Explicación Matriz de Confusión

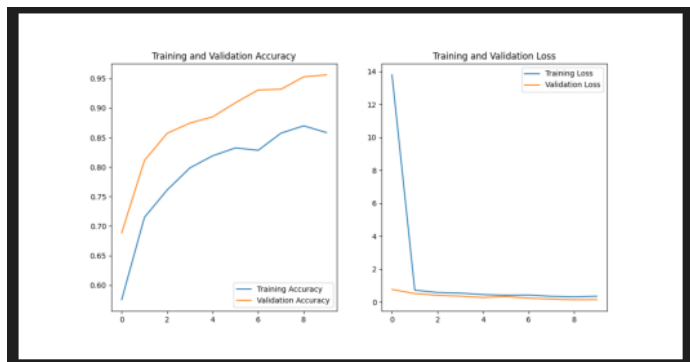
La matriz de confusión presenta una relación entre valores de la siguiente manera:

- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

Como se puede observar se tiene una gran coincidencia de verdaderos positivos, pero existen errores a niveles de Trans-ventricular categorizado como Trans-thalamic, por lo que más adelante se procede a mejorarlo. Para este punto se presenta el caso donde los falsos positivos y falsos negativos son menores a dos cifras y se posee varios valores altos como es el caso de Trans-ventricular categorizado como Trans-thalamic

Figura 28 - Matriz de confusión Segunda Ejecución

Matriz de confusión VGG19 Segunda Ejecución



Explicación Graficas

Para este caso se presenta dos graficas en las cuales se puede encontrar los siguientes hallazgos:

Grafica de accuracy: se puede observar que el modelo tiene el mejor desempeño, en otras palabras, tanto para el caso de los datos de entrenamiento como para el de validación es constante, lo que indica que el modelo está poco sobre ajustando y está generalizando bien. Pero presenta algún sobreajuste dentro de la época 7.

Grafica de Loss: se puede observar que no posee curvas superiores a la data de entrenamiento, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Figura 29- Graficas de entrenamiento y validación Segunda Ejecución

Graficas de entrenamiento y validación VGG 19 Segunda Ejecución

Reporte de clasificación:				
	precision	recall	f1-score	support
0	0.98	0.97	0.98	600
1	0.90	0.97	0.93	600
2	0.98	0.92	0.94	600
accuracy			0.95	1800
macro avg	0.95	0.95	0.95	1800
weighted avg	0.95	0.95	0.95	1800

Figura 30 - Valores de rendimiento

Valores de rendimiento VGG19 Mejorado

Teniendo en cuenta los resultados anteriores se puede determinar que los valores con la ejecución llevada a cabo en el numeral 6.3 no son muy diferentes a los originales, es decir se posee un accuracy del 95% y una precisión del 98% lo cual confirma los valores obtenidos previamente.

Como segundo paso dentro del proceso y teniendo como precepto que se puede mejorar el rendimiento del modelo, se procede a crear la tarea para el manejo de Hiperparámetros, estas fueron realizadas teniendo en cuenta la función Randomsearch, la cual fue configurada con 10 recorridos y se determina como objetivo el mejorar el parámetro de val_accuracy. Por último, se parametriza cada iteración con 10 épocas.

Dando como resultado los siguientes valores de Hiperparámetros para el modelo:


Tabla 17 - Parámetros de Mejoramiento VGG19

Parámetro	Mejor Valor
Neuronas	1536
Dropout	0.2
Learning_rate	0.0007745556188920088

Como siguiente tarea, se realiza la configuración del modelo VGG19 con los Hiperparámetros seleccionados en las tareas de Randomsearch. Luego de modificado y ejecutado con la misma cantidad de épocas que se parametrizo al inicio (10 épocas) se obtuvieron los siguientes resultados de desempeño:

Tabla 18 - Estadísticas Modelo VGG19 mejorado

Modelo	Val_accuracy	Precisión	Recall	F1_score
Vgg19 - Mejorado	0.99	0.99	0.98	0.99
Matriz de confusión	Gráficas de entrenamiento y validación			
Figura 31 - Matriz de confusión	Figura 32 - Gráficas de entrenamiento y validación			
Valores de rendimiento - Figura 33	Valores de rendimiento			



Explicación Matriz de Confusión


La matriz de confusión presenta una relación entre valores de la siguiente manera:

- Trans-Cerebellum (índice 0)
- Trans-thalamic (índice 1)
- Trans-ventricular (índice 2)

Como se puede observar se tiene una gran coincidencia de verdaderos positivos, pero aún se tiene errores a niveles de Trans-ventricular categorizado como Trans-thalamic. Para este punto se llega al caso donde los falsos positivos y falsos negativos son menores a dos cifras en todas sus posibles combinaciones. Lo anterior indica que el modelo tiene un buen desempeño.

Figura 31 - Matriz de confusión Modelo VGG19 Mejorado

Matriz de confusión VGG19 Mejorada



Explicación Graficas

Para este caso se presenta dos graficas en las cuales se pueden encontrar los siguientes hallazgos:

Grafica de accuracy: se puede observar que se tiene el mejor desempeño hasta el momento, en otras palabras, tanto para el caso de los datos de entrenamiento como para el de validación es constante, lo que indica que el modelo está poco sobre ajustando y además se encuentra generalizando bien. Aunque presenta algún sobreajuste luego de la época 5.

Grafica de Loss: se puede observar que no posee curvas superiores a la data de entrenamiento, por lo que se puede afirmar que debido a que las curvas de pérdida de entrenamiento y validación disminuyen juntas y se estabilizan, el modelo está aprendiendo y generalizando correctamente

Figura 32 - Graficas de entrenamiento y validación Modelo VGG19 Mejorado

Graficas de entrenamiento y validación VGG19 Mejorado

```

Reporte de clasificación:
      precision    recall  f1-score   support

     0       0.99      1.00      0.99      600
     1       0.99      0.98      0.99      600
     2       0.99      0.99      0.99      600

 accuracy                   0.99      1800
 macro avg       0.99      0.99      0.99      1800
 weighted avg    0.99      0.99      0.99      1800
  
```

Figura 33 - Valores de rendimiento

Valores de rendimiento VGG19 Mejorado

Teniendo en cuenta los anteriores resultados se puede determinar que pasamos de un 95% a 99% en accuracy y de un 98% a 99% en precisión. Lo anterior nos confirma que este es el mejor modelo teniendo en cuenta los datos y la estructura de la información, por lo que se puede inferir que este último es el más idóneo para la clasificación del plano cerebral.

Todos los procesos de diseño, modelamiento y mejora de los modelos que se realizan en este capítulo fueron desarrollados en Python y ejecutados usando Visual Studio Code. El código puede ser visualizado dentro del siguiente anexo:

Anexo B - 001 - [Proyecto de Grado- Primer Modelo Clasificación de Planos](#)

El anterior documento ayuda a tener una mayor claridad respecto a cómo se generan los resultados anteriormente mencionados.

6.5 Modelo para determinar regiones y la estructura Cavum Septum Pellucidum en las imágenes de ultrasonido

Dentro del proceso para determinar las regiones del cerebro se fueron realizados una serie de tareas las cuales serán explicadas dentro de los siguientes numerales:

6.5.1 Etiquetado de Mascaras

Dentro del proceso fue realizada una tarea de etiquetado de las regiones en las imágenes de ultrasonido. Este proceso fue llevado a cabo por parte de un profesional de obstetricia, el cual uso la herramienta “Labelme” para la definición de las máscaras. Este aplicativo fue escogido debido a que cuenta con una serie de características que permiten generar la data necesaria para los procesos del proyecto de grado, las cuales son:

- Es un aplicativo de uso libre y abierto a la contribución pública.
- Es un aplicativo desarrollado por el MIT Computer Science and Artificial Intelligence Laboratory (CSAIL), lo cual lo respalda como una buena base tecnológica para la generación de las máscaras.
- Permite generar anotaciones sobre imágenes.
- Es una aplicativo ampliamente usado en tareas de visión por computador.

Debido a todas estas características se opta por esta aplicación, lo que garantiza que se cubren las necesidades básicas del proyecto. El proceso anterior permitió obtener un total de 146 imágenes etiquetadas. Adicionalmente, este proceso fue suspendido debido a un hallazgo (artículo [30]) que facilitó al proyecto un total de 1374 imágenes de la misma base de datos ya etiquetadas.

Adicionalmente, se realiza una validación de otras investigaciones en donde se implementa este mismo dataset y se pudo encontrar el artículo de Mahmood Alzubaidi, Marco Agus, Michel Makhoul, Fatima Anver, Khalid Alyafei, Mowafa Househ a. llamado “Large-scale annotation dataset for fetal head biometry in ultrasound images” [30]. El artículo en mención toma la misma base de imágenes que se maneja y adicionalmente agrega otras imágenes de ultrasonido. Además, contiene la data necesaria de las máscaras y puede ser encontrado en la URL: <https://zenodo.org/records/8265464>.

Por otro lado, para tener la certeza que las imágenes correspondían al mismo grupo que ya se manejaban se decide realizar una comparación de las imágenes iniciales versus las nuevas. Este proceso fue realizado mediante el uso de coeficiente de similitud, lo que genero la siguiente grafica de resultados:




Figura 34 - Comparación de imágenes por Rango de Similitud

Cantidad de imágenes por rango de similitud siendo clasificadas como iguales en caso de poseer más de 99%, o diferentes si es menor a 99% y no existen en caso de no encontrarse

la gran mayoría de imágenes (2696) coinciden en un 0.99, este valor indica que son muy similares. Por otro lado 135 de ellas no son exactamente iguales pero su coeficiente de similitud tiene un rango entre 0.9836 y 0.9899 por lo que se considera que la diferencia no es suficiente como para descartar la información. Teniendo en cuenta lo anterior y después de realizado la respectiva validación se determina que se puede usar las máscaras de la nueva fuente de datos como información de ingreso para el proyecto. Lo anterior permite tener un total final de 1396 imágenes etiquetadas, las cuales quedan distribuidas tal y como se muestra en la siguiente figura:




Figura 35 - Distribución de Etiquetas por autor

Distribución de etiquetas por autor, especialista y sin etiqueta

Adicionalmente fueron realizadas tareas de validación de datos para garantizar que las imágenes de la investigación correspondían a imágenes que se tienen dentro del dataset original. Todo este proceso será explicado dentro del proceso de análisis en el siguiente numeral.

6.5.2 Análisis del Dataset

Luego de realizado el proceso de generación u obtención de Mascaras se pudo realizar la tarea de análisis donde se determinó que las imágenes cumplen con las características de calidad y cantidad necesarias para los modelos. Adicionalmente se validó la cantidad de imágenes que poseían un Json de Labelme dando como resultado la siguiente distribución:

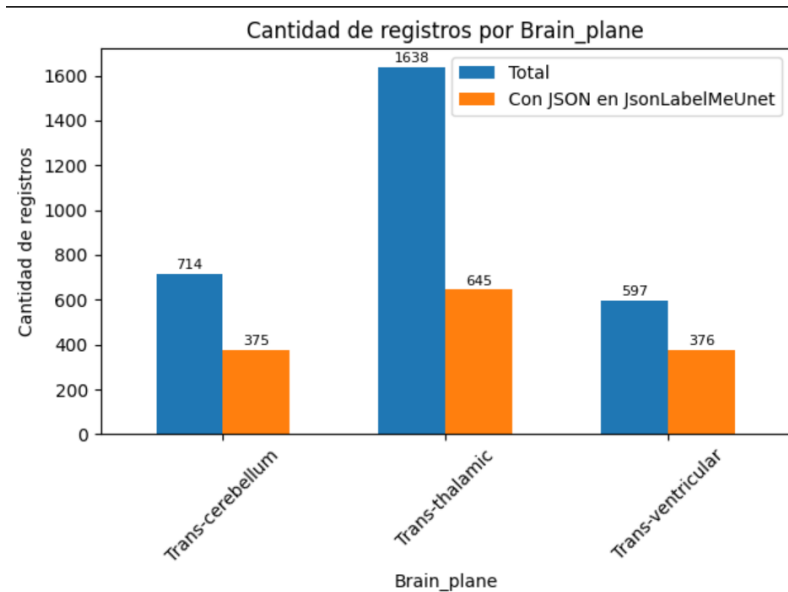


Figura 36 - Distribución de Imágenes por Json Valido por plano craneal

La figura muestra la cantidad de imágenes que poseen un Json de etiquetado validado por Label me

La anterior distribución permite visualizar la cantidad de máscaras que se posee por cada plano cerebral. Teniendo en cuenta que no todas las imágenes tienen máscaras y que únicamente se poseen máscaras de 1396 imágenes, se decide seleccionar únicamente este conjunto como dataset para los modelos.

Otro de los aspectos al que se le realizó un análisis dentro del dataset fue revisar algunas de las imágenes y sus máscaras, esto se permitió determinar que se posee un buen conjunto de datos. A continuación, se presentan algunos ejemplos generados durante este proceso, mostrando las imágenes junto con sus máscaras, como se ilustra en las siguientes figuras:




Figura 37 - Imágenes de planos craneales con etiqueta

En la primera imagen se visualiza un ejemplo de la etiquetación del especialista en obstetricia y en la segunda una etiquetación de las máscaras obtenidas de la revisión sistemática

Luego de finalizada esta tarea se identifica que no solamente se encuentra etiquetado la estructura Cavum Septum Pellucidum, por lo que es necesario una tarea de pre-procesamiento donde se procede a eliminar de los Json las estructuras que no correspondan al objetivo principal del proyecto.

En conclusión, a partir de la tarea del análisis del dataset se obtuvieron los siguientes resultados:

- Se cuenta con 645 imágenes para el plano Trans-thalamic.
- Se cuenta con 376 imágenes para el plano Trans-ventricular.
- Se cuenta con 375 para el plano Trans-Cerebellum.
- Las máscaras tienen más de una forma estructural en su etiquetado.
- No se hace necesario validar tema de nulos debido a que este análisis se realizó para el anterior modelo de clasificación de plano cerebral.

Los anteriores descubrimientos ayudan a determinar y realizar una serie de tareas antes de empezar con el diseño y entrenamiento del modelo de U-net, estas tareas fueron:

1. Se debe realizar un Oversampling y Data Augmentation, esto teniendo en cuenta que apenas se cuenta con 1396 imágenes las cuales tienen una máscara valida, la cual incluye la estructura craneal Cavum Septum Pellucidum.
2. Se debe limpiar los Json de las máscaras para que quede solo una estructura (Cavum Septum Pellucidum)

Las anteriores tareas fueron ejecutadas dentro del proceso de pre-procesamiento de datos y la idea fue generar una cantidad adecuada de registros dentro del dataset para el diseño y entrenamiento del modelo. por otro lado, los datos son considerados válidos y los procesos de análisis solo tomaron en cuenta cantidades, esto debido a que temas como nulos o datos atípicos fueron validados anteriormente.

6.5.3 Pre-procesamiento del dataset

Luego de implementado el proceso de análisis de la información del dataset se realizó las siguientes tareas de pre-procesamiento:

- Selección de imágenes con Json valido.
- Proceso de Oversampling.
- Selección de estructura de interés.
- Proceso de Data Augmentation y Redimensionamiento de Imágenes.
- Generación de conjunto de datos para cada plano cerebral.

Cada una de las tareas mencionadas será detallada en los siguientes numerales

6.5.3.1. Selección de imágenes con Json valido

Como primera tarea de pre-procesamiento se realiza la selección de únicamente las imágenes que poseen un Json de etiquetado con la estructura Cavum Septum Pellucidum lo que género como resultado final la siguiente distribución de imágenes:

Tabla 19 - Distribución por plano de imágenes que tienen Json Valido

Plano Cerebral	Cantidad de Imágenes con Etiquetado
Trans-Thalamic	645
Trans- Ventricular	376
Trans-Cerebellum	375
Total de Imágenes	1.396

6.5.3.2. Proceso de Oversampling

La segunda tarea finalizada dentro del pre-procesamiento de datos fue la generación de un mayor número de registros en el dataset. Esto se realizó con el fin de poseer un balanceo en cada plano cerebral o clase, por lo que se ejecutó un proceso para que se obtuviera 2000 registros por cada clase que existe en el dataset. Esta nueva distribución se puede observar en la siguiente figura:

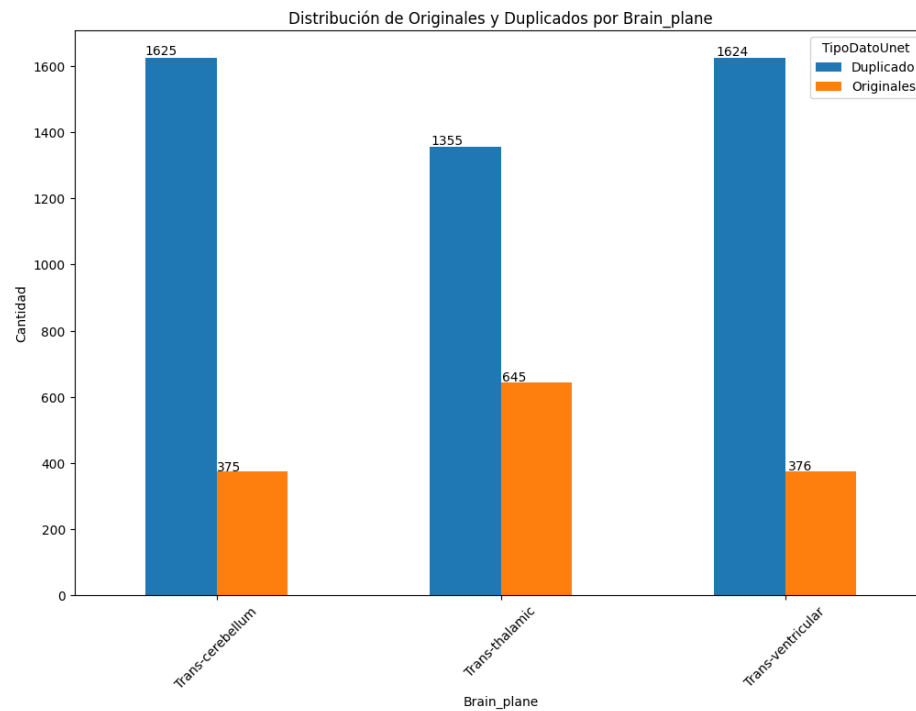


Figura 38 - Distribución de registros con Oversampling

Se muestra la cantidad de registros que fueron creados por el proceso de Oversampling

Como se puede observar en la Figura 38 - Distribución de registros con Oversampling se tiene en naranja los registros que quedaron del proceso de selección y en azul los registros que se crearon por el Oversampling. En conclusión, este proceso genero la siguiente distribución de datos:

Tabla 20 - Distribución de registros generados por Oversampling

Plano	Cantidad registros Originales	Cantidad de Registros Oversampling	Cantidad Final
Trans-Thalamic	645	1.355	2.000
Trans- Ventricular	376	1.624	2.000
Trans-Cerebellum	375	1.625	2.000
Total de Imágenes	1.396	4.604	6.000

Es de tener en cuenta que para este momento dentro del dataset se tienen las imágenes y máscaras de los datos creados por el proceso de Oversampling, pero los nuevos registros contienen la misma imagen original por lo que es necesario un proceso de Data Augmentation.

6.5.3.3 Selección de estructura de interés

Al momento de llevar a cabo el proceso de Oversampling se identificó que el etiquetado de las imágenes estaba mucho más completo y en varios casos los Json contenían más de una estructura craneal. Debido a lo anterior se realizó la eliminación de la información de las estructuras que no hacen parte del análisis de este trabajo y que contenían los archivos Json.

Para detallar un poco mejor la información, es bueno aclarar que todos los archivos Json etiquetados con Labelme originan un archivo de tipo Json que contiene todos los datos necesarios para la identificación de las estructuras. Los archivos anteriormente mencionados contienen un cabezal donde se indica la forma que se etiqueta, seguido los pixeles que dan forma a la imagen. En la siguiente figura se puede ver como quedo un ejemplo de un archivo Json etiquetado con Labelme con varias formas y luego de solo dejamos la estructura que nos interesa (CSP).

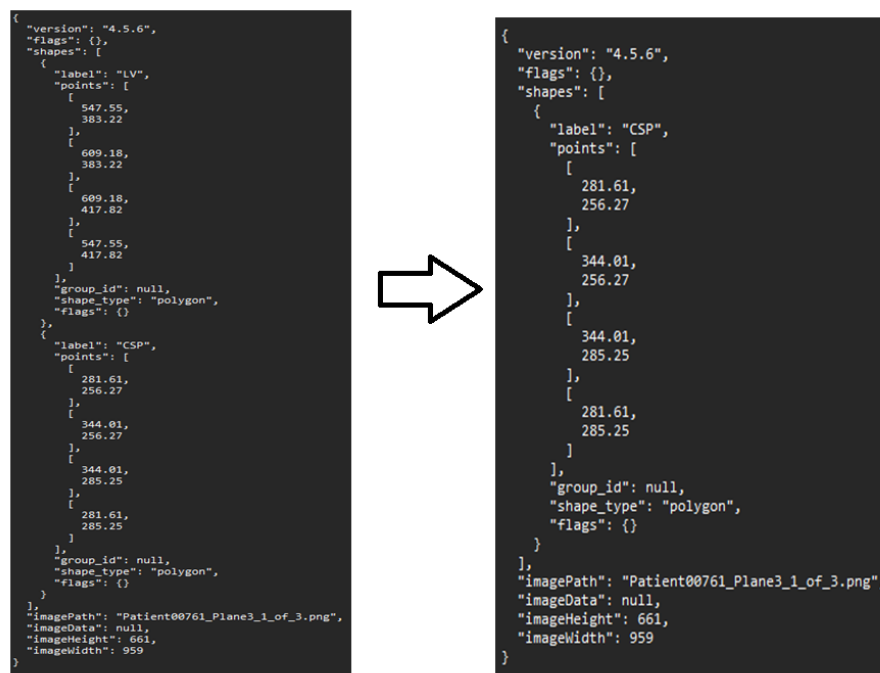


Figura 39 - Proceso de Limpieza Json

Se puede visualizar la eliminación de las otras estructuras y dejamos solo el Cavum Septum Pellucidum

Lo anterior permite que los modelos solo se basen en la estructura craneal deseada, adicionalmente la data eliminada es guardada debido a que podría ser valiosa para otros proyectos futuros. Por último, como parte adicional de este proceso, se decidió realizar una actividad, en la cual se crea una columna nueva que contiene un nombre único, esto es necesario para poder identificar más fácilmente quien es cada uno de los registros.

6.5.3.4. Proceso de Data Augmentation y Redimensionamiento de Imágenes

La siguiente tarea dentro del desarrollo del proyecto fue la creación de imágenes sintéticas. el encargado de este proceso es la técnica de Data Augmentation, la cual fue aplicada tanto a las imágenes como a su respectiva mascara.

La técnica de Data Augmentation aplicada fue sencilla y solo se implementaron funciones de rotaciones e inversiones, estas dos tareas fueron ejecutadas de manera aleatoria es decir en una imagen se pudo aplicar solo rotación o en otra se aplicó rotación e inversión o solo inversión. Este proceso crea nuevas imágenes que hacen que los modelos sean más responsivos a los diferentes cambios que puedan tener los planos craneales.

Por último, antes de iniciar este proceso y debido a que se cuenta con un bajo poder computacional, se hace un redimensionamiento de las imágenes y las máscaras para que el proceso no consuma demasiados recursos. Es decir, todas las imágenes y máscaras creadas por el proceso de Data Augmentation tuvieron como resultado final un tamaño de 224 por 224 pixeles. Este proceso fue validado por medio de una visualización que permite ver el cambio, tal y como se muestra en la Figura 40 - Ejemplo redimensionamiento:




Figura 40 - Ejemplo redimensionamiento

Se muestra el cambio de la imagen con el redimensionamiento y la eliminación de las estructuras no estudiadas

La Figura 40 - Ejemplo redimensionamiento permite ver como se genera la transformación de una imagen con varias estructuras a una imagen con únicamente una sola estructura, además de identificar el cambio generado por el data Augmentation y el redimensionamiento de la imagen.

6.5.3.5. Generación de conjunto de datos para cada plano cerebral

En primera instancia para esta tarea se validaron los rangos de canales de las imágenes y las máscaras dando como resultado que las máscaras tienen un solo canal es decir sus valores oscilan entre 0 o 225. Por otro lado, las imágenes modificadas poseen valores entre 0 y 255, lo que indica que ellas tienen 3 canales o son RGB. Estos procesos son necesarios para el diseño de los modelos que se explican en los siguientes numerales, es decir se debe tener en claro cuál es el formato de entrada para el modelo y cuál será su salida.

Por último, se alistaron las imágenes para ser ingresadas dentro del modelo, este proceso incluye dividir el dataset en un 70% para entrenamiento y un 30% para pruebas, esto quiere decir que cada plano cerebral tuvo 1400 imágenes de entrenamiento y 600 de pruebas. Adicionalmente las imágenes tanto del plano craneal como de la máscara fueron guardadas en un tamaño de 224 por 224 pixeles, de esta manera se garantiza que las imágenes de cada carpeta poseen la calidad, cantidad y características básicas para su ingreso al modelo. Las imágenes y máscaras

fueron almacenadas en la siguiente estructura de carpetas:




Figura 41 - Distribución de Carpetas

Esta imagen contiene la distribución de carpetas creada para almacenar las imágenes y máscaras luego de los procesos de redimensionamiento, Oversampling y data Augmentation

Lo anterior permite que se acote el tiempo de ejecución al poseer los conjuntos de datos guardados en disco en forma de imágenes en formato PNG. Adicionalmente todos los procesos de análisis, pre-procesamiento y creación de conjuntos de los datos para los modelos que se realizan en este capítulo fueron desarrollados en Python y ejecutados usando Visual Studio Code. El código puede ser visualizado dentro del siguiente anexo:

Anexo C - 002 - [Proyecto de Grado- Generación de Conjuntos de Datos para Modelo Identificación Estructura](#)

El anterior documento ayuda a tener una mayor claridad respecto a cómo se generó los resultados anteriormente mencionados

6.5.4 Diseño, mejoramiento, validación e implementación de U-net planos craneales

Dentro de las definiciones realizadas, se determinó la creación de tres modelos de U-Net. uno por cada plano craneal que existe dentro de los datos. Teniendo en cuenta lo anterior se dividió esta sección en las siguientes partes:

- Definición de modelo de U-net Básico.

- Modelo de U-net Plano Trans-Thalamic.
- Modelo de U-net Plano Trans-Ventricular.
- Modelo de U-net Plano Trans-Cerebellum.
- Generación de máscaras predichas para cálculo de área.

Adicionalmente, se aplica la misma estructura básica de modelo para los tres planos cerebrales, pero los valores de ajuste obtenidos por procesos de RandomSearch o HyperBand son diferentes.

6.5.4.1. Definición de modelo de U-net Básico

Para el desarrollo del modelo en primera instancia se realiza la carga de las imágenes y máscaras tanto de pruebas como de entrenamiento. Posterior a la carga de los datos necesarios para el funcionamiento se decide crear un modelo de U-net básico el cual tiene las siguientes características:

- Como entrada se toma las imágenes y máscaras, las cuales tienen una dimensión de 224 por 224 píxeles y tres canales (es decir RGB).
- Se cuenta con una transferencia de conocimiento la cual se generó desde una Red convolucional VGG16.
- Se congelan los pesos de la red neuronal VGG16.
- Se cuenta con 4 capas en la fase de encoder, cada una de las cuales cuentan con MaxPooling y Dropout para el manejo de sobreajuste.
- Se cuenta con una capa de cuello de botella con 1024 filtros.
- Por último, se cuenta con 4 capas en la fase de decoder, cada una de las cuales cuentan con Conv2D, upsampling y Dropout para el manejo de sobreajuste.

Este modelo representa una estructura básica de U-net y se considera que podría funcionar correctamente para la identificación de la Estructura Cavum Septum Pellucidum.

6.5.4.2. Modelo de U-net Plano Trans-Thalamic

Posterior a la tarea de definición del modelo, se procede a realizar los entrenamientos y validaciones de las métricas necesarias. Se debe tener en cuenta que para este y todos los modelos de U-net se toma como métricas principales las siguientes: Precision, Recall, F1-score y accuracy. Adicionalmente se crean las gráficas de curva de pérdida, curva de exactitud, curva de AUC ROC y curva AUC PR. Las cuales pueden ser visualizadas en la siguiente tabla de resultados:

Tabla 21 - Resultados Entrenamiento Modelo Trans-Thalamic

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Thalamic	0.99	0.79	0.80	0.80
	AUC ROC	AUC PR		
	0.90	0.80		
Curva de perdida	Curva de Exactitud			
Figura 42 - Curva de Perdida Modelo Trans-Thalamic	Figura 43 - Curva de Accuracy Modelo Trans-Thalamic			
Curva AUC ROC	Curva AUC PR			
Figura 44 - Curva ROC Modelo Trans-Thalamic	Figura 45 - Curva Precision-Recall Modelo Trans-Thalamic			

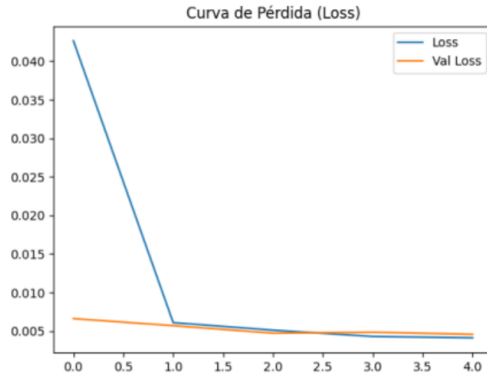


Figura 42 - Curva de Perdida Modelo Trans-Thalamic

Curva de pérdida del modelo Trans-Thalamic Básico

Explicación Grafica

Como se puede observar la gráfica presenta un buen desempeño en términos de pérdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien los datos nuevos. El único aspecto a tener en cuenta es que posee un sobre ajuste luego de la 2 época pero debido a que es muy pequeño no se considera como una posible falla.





Figura 43 - Curva de Accuracy Modelo Trans-Thalamic

Curva de Accuracy del modelo Trans-Thalamic Básico

Explicación de la grafica

Como se puede observar se posee un buen desempeño desde las primeras etapas del modelo pero se identifica un poco de sobreajuste cerca de la 2 época




Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.90 lo que indica que el modelo tiene una probabilidad del 90% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se posee un muy buen rendimiento en la tarea de clasificación.

Figura 44 - Curva ROC Modelo Trans-Thalamic

Curva de ROC del modelo Trans-Thalamic Básico



Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.80 lo que indica que tiene un 80% de posibilidades de identificar los positivos en el dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo aunque se buscara mejorarlo por medio de la búsqueda de Hiperparámetros

Figura 45 - Curva Precision-Recall Modelo Trans-Thalamic

Curva de Precision-Recall del modelo Trans-Thalamic Básico




Figura 46 - Muestra de Mascara Predicha

La imagen muestra la máscara predicha por el modelo de U-net Trans-Thalamic

Como se puede observar se tienen los siguientes valores para el primer diseño de modelo

U-net:

- Accuracy:
99%
- Recall:
80%
- AUC ROC:
90%
- Precision:
79%
- F1-Score:
80%

Teniendo en cuenta los anteriores resultados se puede afirmar que los valores de precision y F1-Score, están un poco bajos por lo que se tendrá únicamente en cuenta para el análisis de mejoramiento el parámetro de la precisión.

6.5.4.3. Mejora e implementación de Modelo de U-net Plano Trans-Thalamic

Teniendo en cuenta los datos obtenidos en la anterior etapa se realiza una búsqueda de Hiperparámetros con base en la métrica de precisión, para esto primero se diseña la misma estructura del modelo u net y se añade como puntos a tener en cuenta los siguientes Hiperparámetros:

- DropOut
- Filters
- LearningRate

Adicionalmente el proceso de búsqueda de Hiperparámetros se realiza por medio de la función HyperBand. Es así como teniendo determinado los Hiperparámetros a mejorar se obtienen los siguientes resultados para realizar la mejora:

Tabla 22 - Resultado Mejoramientos con HyperBand

Parámetro	Mejor Valor
DropOut	0.3
Filters	896
Learning_rate	0.0001535532733848362
Cantidad De Épocas	5

Por último, se tomaron los datos obtenidos en el proceso de ajuste de Hiperparámetros y se vuelve a entrenar el modelo de U-net especificado en el numeral 6.5.4.1. Lo anterior generó los siguientes resultados:

Tabla 23 - Resultados Modelo Trans-Thalamic Mejorado

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Thalamic - Mejorado	0.99	0.79	0.82	0.80
AUC ROC	AUC PR			
0.91	0.81			
Curva de perdida	Curva de Exactitud			
Figura 47 - Curva de Perdida modelo Trans-Thalamic Mejorado	Figura 48 - Curva de Accuracy modelo Trans-Thalamic Mejorado			
Curva AUC ROC	Curva AUC PR			

Figura 49 - Curva ROC modelo Trans-Thalamic Mejorado

Figura 50 - Curva Precision Recall del modelo Trans-Thalamic mejorado




Figura 47 - Curva de Perdida modelo Trans-Thalamic Mejorado

La figura muestra la curva de pérdida del modelo Trans-Thalamic mejorado

Explicación Grafica

Como se puede observar la gráfica presenta un buen desempeño en términos de pérdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien los datos nuevos. El único aspecto a tener en cuenta es que tiene un mayor sobre ajuste luego de la 3 época, pero debido a que es muy pequeño no se considera como una posible falla.




Figura 48 - Curva de Accuracy modelo Trans-Thalamic Mejorado

La figura muestra la curva de Accuracy del modelo Trans-Thalamic mejorado

Explicación de la grafica

Como se puede observar se tiene un buen desempeño desde las primeras etapas del modelo pero existe un poco de sobreajuste cerca de la 3 época


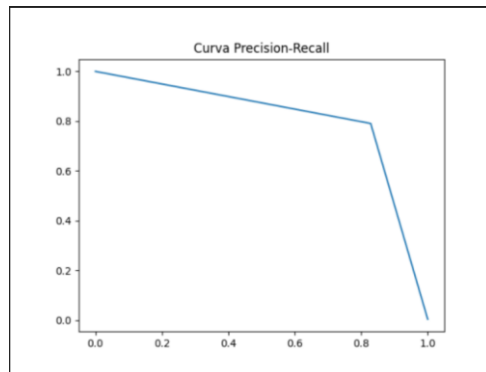


Figura 49 - Curva ROC modelo Trans-Thalamic Mejorado

La figura muestra la curva de ROC del modelo Trans-Thalamic mejorado

Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.91 lo que indica que el modelo tiene una probabilidad del 91% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se tiene un muy buen rendimiento en la tarea de clasificación. Para estos casos se ve mejorado el modelo en un 1% para la curva AUC ROC



Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.81 lo que indica que tiene un 81% de posibilidades de identificar los positivos en el dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo.

Para estos casos se ve mejorado el modelo en un 1% para la curva AUC PR

Figura 50 - Curva Precision Recall del modelo Trans-Thalamic mejorado

La figura muestra la curva de Precision Recall del modelo Trans-Thalamic mejorado




Figura 51 - Muestra de mascara Predicha con Modelo Trans-Thalamic Mejorado

La figura muestra la máscara predicha generada por el modelo Trans-Thalamic mejorado

El anterior modelo antes del proceso de mejoramiento tenia los siguientes valores:

- Precision:
79.3%
- Recall:
80.6%
- F1-Score:
80%
- Accuracy:
99%
- AUC
ROC:90%
- AUC-PR:
80%

luego de aplicar los valores de mejoramiento al modelo se pueden observar los siguientes valores:

- Precision:
79.1%
- Recall:
82.8%
- F1-Score:
80.9%
- Accuracy:
99%
- AUC
ROC:91%
- AUC-PR
:81%

Luego de que se realiza el proceso de búsqueda de Hiperparámetros se obtiene un mejoramiento en el recall, dentro del cual aumentamos en 2.8%, además de aumentos en el F1-Score en 9%, AUC ROC en un 1% y de AUC PR también en un 1%. Con estas mejoras se da por finalizado el proceso de selección del modelo para el plano Trans-Thalamic y se procedió al desarrollo de los modelos con los otros planos Craneales.

Otro aspecto a mejorar es la precisión la cual se incrementaría si se aumenta las capas de

encoder, esto permitiría que el modelo entienda características más detalladas de la estructura. Adicionalmente, todos los procesos de diseño, modelamiento y mejora de los modelos que se describen en este capítulo fueron desarrollados en Python y ejecutados usando Visual Studio Code. El código puede ser visualizado dentro del siguiente anexo:

Anexo D - 003-1 - [Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans-Thalamic](#)


El anterior documento brinda una mayor claridad respecto a cómo se genera los resultados anteriormente mencionados.

6.5.4.4. Modelo de U-net Plano Trans-Ventricular

Posterior a la tarea de definición del modelo básico, se realiza los entrenamientos y validaciones de las métricas necesarias. Se debe tener en cuenta que para este y todos los modelos de Unet se toma como métricas principales las siguientes: precision, Recall, F1-score y accuracy. Adicionalmente se crearon las gráficas de curva de perdida, curva de exactitud, curva de AUC ROC y curva AUC PR. Las cuales pueden ser visualizadas en la siguiente tabla de resultados:

Tabla 24 - Resultado Modelo Básico Trans-Ventricular

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Ventricular	0.99	0.849	0.771	0.808
AUC ROC	AUC PR			
0.885	0.81			
Curva de perdida	Curva de Exactitud			
Figura 52 - Curva de Perdida Modelo Básico Trans-Ventricular	Figura 53 - Curva de Accuracy Modelo Básico Trans-Ventricular			
Curva AUC ROC	Curva AUC PR			
Figura 54 - Curva ROC del Modelo Básico Trans-Ventricular	Figura 55 - Curva de Precision-Recall del Modelo Básico Trans-Ventricular			



Explicación Grafica

Como se puede observar la gráfica presenta un buen desempeño en términos de perdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien los datos nuevos. Adicionalmente cabe recalcar que no hay sobre ajuste visible en la gráfica.

Figura 52 - Curva de Perdida Modelo Básico Trans-Ventricular

La imagen muestra la curva de Perdida Modelo Básico Trans-Ventricular




Figura 53 - Curva de Accuracy Modelo Básico Trans-Ventricular

La imagen muestra la curva de Accuracy Modelo Básico Trans-Ventricular

Explicación de la grafica

Como se puede observar se tiene un buen desempeño desde las primeras etapas del modelo , además se identifica un poco de sobreajuste cerca de la 2 época, pero los rangos son muy pequeños por lo que Se considera que no es representativo para el caso.




Figura 54 - Curva ROC del Modelo Básico Trans-Ventricular

La imagen muestra la curva ROC del Modelo Básico Trans-Ventricular

Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.885 lo que indica que el modelo tiene una probabilidad del 88.5% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se tiene un muy buen rendimiento en la tarea de clasificación.




Figura 55 - Curva de Precision-Recall del Modelo Básico Trans-Ventricular

La imagen muestra la curva de Precision-Recall del Modelo Básico Trans-Ventricular

Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.81 lo que indica que tiene un 81% de posibilidades de identificar los positivos en nuestro dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo.




Figura 56 - Muestra de mascara predicha por el modelo Básico Trans-Ventricular

La imagen contiene la máscara predicha por el modelo Trans-Ventricular Básico

Como se puede observar se obtuvieron los siguientes valores para el primer diseño de modelo U-net sobre el plano Trans-Ventricular:

- Accuracy: 99%
- Recall: 77%
- AUC-ROC: 88%
- Precisión: 84%
- F1-Score: 80%

Teniendo en cuenta los anteriores resultados se puede afirmar que los valores de precisión y F1-Score, están un poco bajos por lo que se tendrá únicamente en cuenta para el análisis de mejoramiento el parámetro de la precisión.

6.5.4.5. Mejora e implementación de Modelo de U-net Plano Trans- Ventricular

Teniendo en cuenta los datos obtenidos en la anterior etapa se realiza una búsqueda de Hiperparámetros con base en la métrica de precisión, para esto primero se diseña la misma estructura del modelo u net y se añade como puntos a tener en cuenta los siguientes Hiperparámetros:

- DropOut
- Filters
- LearningRate

Adicionalmente el proceso de búsqueda de Hiperparámetros se realiza por medio de la función RandomSearch. Es así como luego de definidos los Hiperparámetros a mejorar se obtienen los siguientes resultados para realizar la mejora:

Tabla 25 - Resultado Mejoramientos con RandomSearch

Parámetro	Mejor Valor
DropOut	0.6
Filters	896
Learning_rate	0.0008013308557761683
Cantidad De Épocas	5

Por último, se toman los datos obtenidos en el proceso de ajuste de Hiperparámetros y vuelve a entrenar el modelo de U-net especificad en el numeral 6.5.4.1. Lo anterior genero los siguientes resultados:

Tabla 26 - Resultados Modelo Trans-Ventricular Mejorado

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Ventricular - Mejorado	0.99	0.849	0.77	0.811
AUC ROC	AUC PR			
0.88	0.814			
Curva de perdida	Curva de Exactitud			
Figura 57 - Curva de Perdida del modelo Trans-Ventricular Mejorado	Figura 58 - Curva de Accuracy del modelo Trans-Ventricular Mejorado			
Curva AUC ROC	Curva AUC PR			
Figura 59 - Curva ROC del modelo Trans-Ventricular Mejorado	Figura 60 - Curva Precision-Recall del modelo Trans-Ventricular Mejorado			




Figura 57 - Curva de Perdida del modelo Trans-Ventricular Mejorado

La imagen muestra los resultados de la curva de Perdida modelo Trans-Ventricular Mejorado

Explicación Grafica

Como se puede observar la gráfica presenta un buen desempeño en términos de perdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien a datos nuevos. El único aspecto a tener en cuenta es que tiene un mayor sobre ajuste luego de la 3 época, pero debido a que es muy pequeño no se considera como una posible falla.





Figura 58 - Curva de Accuracy del modelo Trans-Ventricular Mejorado

La imagen muestra los resultados de la curva de accuracy modelo Trans-Ventricular Mejorado

Explicación de la grafica

Como se puede observar se tiene un buen desempeño desde las primeras etapas del modelo, además existe un poco de sobreajuste cerca de la 3 época pero debido a que los rangos de sobre ajuste son tan pequeños no se considera un mal modelo.




Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.888 lo que indica que el modelo tiene una probabilidad del 88.8% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se tiene un muy buen rendimiento en la tarea de clasificación.
 Para estos casos se incrementa los valores en un 0.4% para la curva AUC ROC

Figura 59 - Curva ROC del modelo Trans-Ventricular Mejorado

La imagen muestra los resultados de la curva ROC del modelo Trans-Ventricular Mejorado



Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.814 lo que indica que tiene un 81.4% de posibilidades de identificar los positivos en el dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo.
 Para estos casos se ve mejorado el modelo en un 0.44% para la curva AUC-PR

Figura 60 - Curva Precision-Recall del modelo Trans-Ventricular Mejorado

La imagen muestra los resultados de la curva Precision-Recall del modelo Trans-Ventricular Mejorado




Figura 61 - Muestra de imagen predicha Modelo Mejorado Trans-Ventricular

La imagen muestra la máscara predicha por el modelo mejorado Trans-Ventricular

El anterior modelo sin mejoramiento posee los siguientes valores de desempeño:

- Precision: 84.9%
- Recall: 77.1%
- F1-Score: 80.8%
- Accuracy: 99.8%
- AUC-ROC: 88.5%
- AUC-PR: 81%

luego de aplicarse los valores de mejoramiento al modelo se puede observar los siguientes valores:

- Precision: 84.9%
- Recall: 77.7%
- F1-Score: 81.1%
- Accuracy: 99.8%
- AUC-ROC: 88.8%
- AUC-PR: 81.4%

Luego de que de realizarse el proceso de búsqueda de Hiperparámetros se obtiene un mejoramiento en el recall dentro del cual se aumenta en un 0.6%, además de aumentos en el F1-Score de 0.3%, AUC ROC del 0.4% y de AUC PR también del 0.4%, con estas mejoras se da por finalizado el proceso de selección del modelo para el plano Trans-Ventricular y se procedió al desarrollo de los modelos con los otros planos Craneales.

Otro aspecto a mejorar es la precisión, la cual se incrementaría al aumentar las capas de encoder. Esto permitiría que el modelo entienda características más detalladas de la figura para el plano Trans-Ventricular. Adicionalmente, todos los procesos de diseño, modelamiento y mejora de los modelos descritos en este capítulo fueron desarrollados utilizando Python y ejecutados en Visual Studio Code. El código puede ser visualizado en el siguiente anexo:

Anexo E - 003-2 - [Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans-Ventricular](#)

El anterior documento ayuda a tener una mayor claridad respecto a cómo se generó los resultados anteriormente mencionados.

6.5.4.6. Modelo de U-net Plano Trans-Cerebellum

Posterior a la tarea de definición del modelo básico, se procedió a realizar los entrenamientos y validaciones de las métricas necesarias. Es importante considerar que para este y todos los modelos de Unet se consideran las siguientes métricas: Precision, Recall, F1-score y accuracy. Adicionalmente se generaron las gráficas de curva de perdida, curva de exactitud, curva de AUC ROC y curva AUC PR. Las cuales pueden ser visualizadas en la siguiente tabla de resultados:

Tabla 27 - Resultado Modelo Básico Trans-Cerebellum

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Cerebellum	0.99	0.844	0.847	0.846
AUC ROC	AUC PR			
0.923	0.846			
Curva de perdida	Curva de Exactitud			
Figura 62 - Curva de Perdida del Modelo	Figura 63 - Curva de Accuracy del Modelo			

Básico Trans-Cerebellum


Básico Trans-Cerebellum

Curva AUC ROC

Curva AUC PR

Figura 64 - Curva ROC del Modelo Básico Trans-Cerebellum

Figura 65 - Curva de Precision-Recall del Modelo Básico Trans-Cerebellum




Explicación Grafica

Como se observa en la gráfica presenta un buen desempeño en términos de pérdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien los datos nuevos. Adicionalmente cabe aclarar que no hay sobre ajuste visible en la gráfica.

Figura 62 - Curva de Perdida del Modelo Básico Trans-Cerebellum

La imagen muestra los resultados de la curva de Perdida del Modelo Básico Trans-Cerebellum




Explicación de la grafica

Como se puede observar se tiene un buen desempeño desde las primeras etapas del modelo, esto sin verse un evidente sobre ajuste en el proceso lo que indica un buen rendimiento y generalización.

Figura 63 - Curva de Accuracy del Modelo Básico Trans-Cerebellum

La imagen muestra los resultados de la curva de Accuracy del Modelo Básico Trans-Cerebellum




Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.923 lo que indica que el modelo tiene una probabilidad del 92.3% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se obtuvo un muy buen rendimiento en la tarea de clasificación.

Figura 64 - Curva ROC del Modelo Básico Trans-Cerebellum

La imagen muestra los resultados de la Curva ROC del Modelo Básico Trans-Cerebellum



Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.846 lo que indica que tiene un 84.6% de posibilidades de identificar los positivos en el dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo.

Figura 65 - Curva de Precision-Recall del Modelo Básico Trans-Cerebellum

La imagen muestra los resultados de la Curva de Precision-Recall del Modelo Básico Trans-Cerebellum




Figura 66 - Muestra de mascara Predicha Modelo Básico Trans-Cerebellum

La imagen muestra la máscara predicha por el modelo Básico Trans-Cerebellum

Como se puede observar se obtuvieron los siguientes valores para el primer diseño de modelo Unet para el plano Trans-Cerebellum:

- Accuracy: 99.8%
- Recall: 84.7%
- AUC-ROC: 92.3%
- Precision: 84.4%
- AUC PR: 84.6%
- F1-Score: 84.6%

Teniendo en cuenta lo anterior se identifica que los valores de Precisión y F1-Score, se encuentran un poco bajos por lo que el análisis se centrara en el mejoramiento de la precisión.

6.5.4.7. Mejora e implementación de Modelo de U-net Plano Trans- Cerebellum

Teniendo en cuenta los datos obtenidos en la anterior etapa se implementa una búsqueda de Hiperparámetros con base en la métrica de precisión, para esto primero se diseña la misma estructura del modelo u-net y se procede a aplicar los siguientes Hiperparámetros:

- Dropout
- Filters
- LearningRate

Adicionalmente el proceso de búsqueda de Hiperparámetros se realiza por medio de la

función RandomSearch. Es así como definidos los Hiperparámetros a mejorar, se obtuvieron los siguientes resultados:

Tabla 28 - Resultado Mejoramientos con RandomSearch

Parámetro	Mejor Valor
DropOut	0.3
Filters	768
Learning_rate	0.00026798596778915376
Cantidad De Épocas	5

Por último, se toman los datos obtenidos en el proceso de ajuste de Hiperparámetros y vuelve a entrenar el modelo de Unet especificado en el numeral 6.5.4.1. Lo anterior generó los siguientes resultados:

Tabla 29 - Resultados Modelo Trans-Cerebellum Mejorado

Modelo	Val_accuracy	Precisión	Recall	F1_score
Unet-Vgg16 Cerebellum - Mejorado	0.99	0.851	0.902	0.876
AUC ROC	AUC PR			
0.951	0.877			
Curva de perdida	Curva de Exactitud			
Figura 67 - Curva de Perdida del Modelo Trans-Cerebellum Mejorado	Figura 68 - Curva de Accuracy del Modelo Trans-Cerebellum Mejorado			
Curva AUC ROC	Curva AUC PR			
Figura 69 - Curva ROC del Modelo Trans-Cerebellum Mejorado	Figura 70 - Curva de Precision-Recall del Modelo Trans-Cerebellum Mejorado			



Explicación Grafica

Como se puede observar la gráfica presenta un buen desempeño en términos de perdida, ósea que el modelo está aprendiendo correctamente los datos de entrenamiento y generaliza bien los datos nuevos. El único aspecto a tener en cuenta es que tiene un mayor sobre ajuste luego de la 1.5 época, pero debido a que es muy pequeño el valor de sobre ajuste no se considera como una posible falla.

Figura 67 - Curva de Perdida del Modelo Trans-Cerebellum Mejorado

La imagen muestra los resultados de la curva de Perdida del Modelo Trans-Cerebellum Mejorado

Explicación de la grafica

Como se puede observar se tiene un buen desempeño desde las primeras etapas del modelo pero se observa un poco de sobreajuste cerca de la 1 época, pero se considera que debido a que los valores de sobreajuste son tan pequeños es un buen modelo a ser tomado en cuenta.




Figura 68 - Curva de Accuracy del Modelo Trans-Cerebellum Mejorado

La imagen muestra los resultados de la curva de Accuracy del Modelo Trans-Cerebellum Mejorado

Explicación de la grafica

Como se puede observar la gráfica posee un valor de 0.951 lo que indica que el modelo tiene una probabilidad del 95.1% de asignar un puntaje más alto a un ejemplo positivo que a un ejemplo negativo, esto implica que se tiene un muy buen rendimiento en la tarea de clasificación.

Para estos casos se incrementa los valores en un 3.1% para la curva AUC ROC

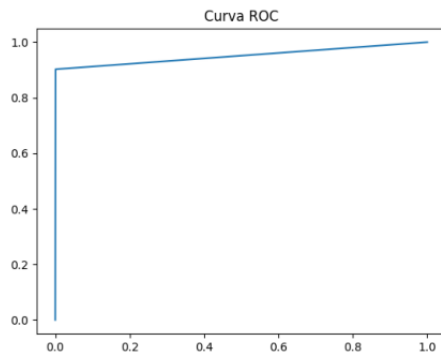


Figura 69 - Curva ROC del Modelo Trans-Cerebellum Mejorado

La imagen muestra los resultados de la Curva ROC del Modelo Trans-Cerebellum Mejorado

Explicación de La grafica

Como se puede observar el valor que tiene la curva en su AUC-PR es de 0.877 lo que indica que tiene un 87.7% de posibilidades de identificar los positivos en el dataset. Se considera que este es un buen valor e indica un buen desempeño por parte del modelo.

Para estos casos se ve mejorado el modelo en un 3.1% para la curva AUC-PR




Figura 70 - Curva de Precision-Recall del Modelo Trans-Cerebellum Mejorado

La imagen muestra los resultados de la curva de Precision-Recall del Modelo Trans-Cerebellum Mejorado




Figura 71 - Muestra de imagen predicha del modelo Trans-Cerebellum Mejorado

La imagen muestra la máscara predicha por el modelo Trans-Cerebellum Mejorado

Teniendo en cuenta los anterior se identifica que el modelo original sin mejoramiento tenia los valores de:

- Precision: 84.4%
- Recall: 84.7%
- F1-Score: 84.6%
- Accuracy: 99.8%
- AUC-ROC: 92.3%
- AUC-PR: 84.6%

luego de implementar los valores de mejoramiento al modelo se puede observar los siguientes valores

- Precision: 85.1%
- Recall: 90.2%
- F1-Score: 87.6%
- Accuracy: 99.9%
- AUC-ROC: 95.1%
- AUC-PR: 87.7%

Teniendo en cuenta los resultados se considera que hubo un mejoramiento en el recall en el cual se aumenta un 5.5%, además de aumentos en el F1-Score de 3.0%, AUC ROC del 2.8%, una precisión 0.7% y de AUC PR también del 3.1%, con estas mejoras se da por finalizado el proceso de selección del modelo para el plano Trans-Cerebellum. Adicionalmente todos los procesos de diseño, modelamiento y mejora de los modelos implementados en este capítulo fueron desarrollados en Python y ejecutados utilizando Visual Studio Code. El código puede ser visualizado dentro del siguiente anexo:

Anexo F - 003-3 - [Proyecto de Grado- Segundo Modelo Identificación Estructura - Trans-Cerebellum](#)

El anterior documento proporciona apoyo para obtener una mayor claridad respecto a cómo se generaron los resultados anteriormente mencionados.

6.5.4.8. Generación de máscaras predichas para cálculo de área

Como último paso de cada uno de los modelos explicados anteriormente se procede a almacenar un total de 10 ejemplos en disco las siguientes imágenes:

- Imagen Original
- Mascara Original
- Mascara Predicha

El objetivo de este almacenamiento es utilizar las máscaras predichas para calcular el área

de la estructura Cavum Septum Pellucidum y determinar una posible normalidad o anormalidad de la estructura. Este proceso se explica en el siguiente capítulo. Cabe aclarar que las imágenes fueron almacenadas en la distribución de carpetas que se detalla a continuación.




Figura 72 - Distribución de Carpetas Mascaras Predichas

La imagen muestra las carpetas que guardan las imágenes, máscaras y máscaras predichas que fueron generadas por cada modelo de U-net en cada plano Cerebral

6.6 Resumen de las Actividades

Ahora brindaremos un resumen sobre el desarrollo de las actividades planeadas para el segundo objetivo y el cual finalizamos de manera satisfactoria:

Tabla 30 - Resumen de resultados Segundo Objetivo

Tarea: Construir conjunto de datos

Se generó un dataset de 6000 imágenes donde se aplicaron técnicas de Oversampling y data Augmentation para generar nuevos registros e imágenes sintéticas que permitan un mejor entrenamiento de los modelos. Por último, se crean dos carpetas las cuales almacenan los conjuntos de pruebas y entrenamiento, los cuales servirán de como data de ingreso para la validación de los posibles modelos para la clasificación del plano cerebral.

Tarea: Definir e implementar un modelo de aprendizaje supervisado basado en Deep Learning para la identificación del plano

Se determinaron cuáles serían los modelos a tener en cuenta para este proceso los cuales fueron: Resnet50, Resnet 101, VGG16 y VGG19. Los modelos fueron seleccionados debido a las ventajas que presentan dentro del análisis de imágenes médicas. Por otro lado, determinamos una estructura básica de red neuronal

convolucional aplicable a todos los modelos. La estructura seleccionada fue la siguiente: Primero tenemos una capa de transferencia de aprendizaje, Segundo poseemos una capa de flatten, que se encarga de transformar las matrices multidimensionales resultantes de las capas convolucionales en un vector unidimensional, Tercero tenemos una capa densa activada con una función relu. Cuarto tenemos una capa de dropout que nos colaborara con el sobreajuste del modelo. Por último, tenemos una capa de salida con 3 categorías y una función de activación softmax. Con esta estructura se validó los procesos de entrenamiento, obteniendo como mejor modelo al VGG19 esto debido a que posee un buen accuracy superior al 95% y una pérdida de 13%.

Tarea: Validar el modelo de aprendizaje supervisado

Se realiza el entrenamiento del modelo vgg19 con 10 épocas dando y obtenemos un porcentaje de accuracy del 98%, pensamos que se podría mejorar por lo cual se procede a realizar validación de Hiperparámetros

Tarea: Ajustar el modelo dependiendo de las validaciones

Se realizó una búsqueda de Hiperparámetros por medio de un Randomsearch donde se obtiene el mejor conjunto y se configura el modelo VGG19 para determinar si mejora o no dentro de sus valores. Luego de llevado a cabo la ejecución del modelo podemos ver que pasamos de un 95% a 99% en accuracy y de un 98% a 99% en precisión por lo que este modelo mejorado fue el que se determinó como modelo final para la clasificación del plano cerebral.

Tarea: Determinar las regiones dentro de las imágenes de ultrasonido que corresponden a la estructura objetivo

Dentro de este proceso realizamos un descubrimiento que nos colaboró en el proceso de etiquetado de información, se pudo validar que otro investigador ya tenía 1374 mascarar las cuales contenían la estructura a analizar. Teniendo en cuenta lo anterior tomamos 146 mascarar producidas por nuestro especialista y 1250 mascarar que provienen de la otra investigación como data para el modelo de U-net a desarrollar.

Tarea: Definir e implementar una arquitectura de una red neuronal basada en Deep Learning

Se define que por temas computaciones y de rendimiento se diseñaran un modelo de Unet por cada plano cerebral, por lo que las tareas de validación y ajuste se realizaran para cada modelo. Adicionalmente se determina usar modelos básicos junto con transferencia de conocimientos basados en una red neuronal VGG16, esto nos ayudó a obtener un mejor desempeño de los modelos.

Tarea: Validar el modelo de aprendizaje supervisado

Para las tareas de validación de los modelos de U-net se realiza el entrenamiento de cada uno de los modelos dando como resultados de 99% de accuracy, pero obtuvimos valores algo bajos en la precisión.

Tarea: Ajustar el modelo dependiendo de las validaciones

Para el tema de ajuste de Hiperparámetros se ejecutó la búsqueda del mejor conjunto aplicando en el caso del modelo Trans-thalamic una función de HyperBand, mientras que para los otros modelos se aplicó la función de Random_search. Las mejoras que se observaron ser encontraron entre los rangos de 0.3% y 5.5%.

Todo el proceso presento algunos inconvenientes de tiempo debido a temas tales como desconocimiento o falta de poder computacional, pero fueron finalizados de manera exitosa.

7 MÉTRICAS DE EVALUACIÓN DE LA ESTRUCTURA CSP EN TÉRMINOS DE NORMALIDAD O ANORMALIDAD

7.1. Definición y Generación de métricas

Para el proceso de la definición y generación de métricas, se realizó la tarea de medir el alto y el ancho de las máscaras predichas, las cuales fueron guardadas en los procesos generados en el anterior capítulo. A continuación, se muestra la Figura 73 - Mascara Original y Predicha en la que se crearon la máscara origina y predicha (la máscara original está en color rojo y en color azul la máscara predicha por el modelo)




Figura 73 - Mascara Original y Predicha

Se muestra la imagen de un plano Trans-Cerebellum con la máscara original (en Rojo) y la máscara predicha por el modelo (En Azul)

Luego de finalizado el proceso de validación de las máscaras de manera visual se procede a calcular el contorno de cada una de las estructuras de tal manera que permitiera calcular los datos necesarios para este proceso. En la Figura 74 - Mascaras se puede observar cómo se rodea cada mascara con el mínimo contorno posible




Figura 74 - Mascaras

Mascaras original enmarcada en rojo y mascara predicha por modelo enmarcada en azul

Por último, uno de los aspectos principales para el cálculo del alto y el ancho fue la conversión de pixeles a milímetros, esto se hace necesario para obtener las distancias. El proceso requiere que se

calcule el PPI o pixeles por pulgada. El proceso de cálculo del PPI se realizó teniendo en cuenta que cada imagen tiene 224 por 224 pixeles, además de un alto de 18.97 milímetros lo que da como resultado un PPI de 229.92. Esto es consistente debido a que los PPI más usados como estándar para impresión de alta calidad es de 300 PPI.

Ahora como siguiente paso en la definición de normalidad o anormalidad se decidió tener en cuenta dos puntos de vistas que fueron los que se determinaron en el anterior numeral de la revisión sistemática, estos aspectos son:

- Se tuvo en cuenta que cuando se realizó los procesos de pre-procesamiento las imágenes fueron redimensionadas a 224 por 224 pixeles por lo que considerar dimensiones especificadas dentro de los artículos sería opuestas o contraproducente para la toma de decisiones.
- **Diagnostico por Tamaño:** Teniendo en cuenta lo anterior, existe precedentes en algunos artículos para inferir que el tamaño es una posible forma de determinación de la anormalidad por lo que este será el primer aspecto a tener en cuenta. Es decir, en caso que el largo sea 30% más grande que el ancho o en caso de no existir la estructura se considera anómalo, de lo contrario será una normalidad.
- **Diagnostico por Evaluación de Dataframe:** Por otro lado, a lo largo de todo el proceso de evaluación en conjunto con el especialista en obstetricia se pudo determinar que la mayoría de imágenes evaluadas corresponden a casos de normalidad. Por lo que otra manera de confirmar la normalidad o anormalidad de la estructura se puede realizar teniendo en cuenta las medidas de media y desviación estándar, si uno de los parámetros de ancho o alto es superior a la media más o menos la desviación estándar, se podría considerar como una anormalidad, de lo contrario si está en el rango se considera normal.

Teniendo en cuenta estas dos formas de calcular la anormalidad se decidió crear una serie de imágenes y un dataframe en donde se aplica estos dos conceptos.




Figura 75 - Imágenes Con Diagnosticas

La imagen las dos imágenes presentan las medidas de largo y ancho y un dictamen de normalidad u anormalidad basado en tamaño (la

imagen izquierda es normal y la derecha anormal)

Las anteriores imágenes permiten ver de una manera simple varias métricas esenciales que se utilizaron para definir una normalidad u anormalidad. Los valores que se observan son los siguientes: largo, ancho, forma de la estructura (mascara predicha por el modelo), contorno, radio y diagnostico (este es evaluado bajo el precepto de tamaño)

A continuación, se muestran los resultados obtenidos por los dos procesos de determinación de normalidad o anormalidad. Dentro del primero se analiza el caso de diagnóstico por tamaño donde se obtuvieron los siguientes resultados:




Figura 76 - Distribución de Imágenes por Diagnostico basado en el tamaño

La grafica muestra la cantidad de imágenes por plano cerebral junto con el diagnostico obtenido al aplicar un esquema de evaluación por tamaño.

La anterior distribución de los casos de normalidad o anormalidad se pueden resumir de la siguiente manera, para el caso del plano Trans-Cerebellum la mayoría corresponden a estructuras normales, por el contrario, en el plano Trans-Ventricular gran parte de los casos corresponden a anomalías en la estructura y por último el plano Trans-Thalamic esta balanceado con la misma cantidad de casos para anomalías y normalidades.

Ahora se procedió a analizar el segundo método para la detección de la anomalía o normalidad, dentro del cual primero se realiza el cálculo de la media, y desviación estándar a los valores de largo y ancho de cada uno de las 30 imágenes que se tomaron como muestras. Para nuestro caso puntal, los resultados finales se pueden observar en la Tabla 31 - Medidas Por Plano Craneal Calculadas, los cuales fueron divididos por cada plano cerebral para obtener un mejor espectro de plano cerebral:

Tabla 31 - Medidas Por Plano Craneal Calculadas

Plano cerebral	Media del largo	Desviación Estándar del Largo	Media del Ancho	Desviación Estándar Del Ancho

Trans-Cerebellum	1.659467	0.127470	1.37160	0.148267
Trans-Thalamic	1.320800	0.222938	0.999067	0.238807
Trans-Ventricular	1.388533	0.731821	0.948267	0.452964

Lo anterior permite identificar la existencia de una posible anomalía, la cual se determinaría si el valor del ancho o del largo de la estructura se encuentra por fuera de la media más o menos su desviación. Este último cálculo permitió generar la Figura 77 - Distribución de Imágenes por Diagnóstico basado en la Desviación Estándar :




Figura 77 - Distribución de Imágenes por Diagnóstico basado en la Desviación Estándar

La grafica muestra la distribución por plano cerebral de las imágenes que fueron categorizadas como normales o anómalas teniendo en cuenta la media y desviación del conjunto de datos

Como se puede observar en este enfoque la cantidad de anomalías se ve mucho más reducida y son más la cantidad de imágenes con dictamen de normalidad que se encuentran en el dataset. Para el final del ejercicio se obtuvo como resultado que el plano Trans-Cerebellum esta balanceado con el mismo número de casos para normalidad y anomalía, mientras que los planos Trans-Thalamic y Trans-Ventricular son más los casos de normalidad dentro de las imágenes.

Todos los procesos de generación de imágenes, medidas, análisis y determinación de dictamen realizados sobre las máscaras predichas que fueron llevados a cabo en este capítulo se ejecutaron en Python usando Visual Studio Code. El código puede ser visualizado dentro del siguiente anexo:

Anexo G - 004 - [Proyecto de Grado- Calculo de Anormalidad o Normalidad](#)

El anterior documento proporciona una mayor claridad respecto a cómo se generó los resultados anteriormente mencionados. Adicionalmente cabe aclarar que, con esta última parte del sistema, lo que se busca es generar una alerta para los especialistas que pudiera ser tenida en cuenta dentro de un análisis más minucioso por parte de expertos en el área. No es un diagnóstico final, sino una herramienta que permite resaltar posibles anomalías. El motivo para determinar una posible anomalía y no un diagnóstico certero se debe a que la base de datos utilizada y los estudios o trabajos encontrados no contienen un criterio de evaluación claro que

nos permita brindar un diagnóstico, teniendo en cuenta lo anterior se podría realizar una mejora al proyecto al identificar un diagnóstico teniendo en cuenta los datos y modelos que ya se poseen.

7.2. Resumen de actividades

Para el tercer objetivo, se desarrollaron las siguientes tareas, las cuales fueron finalizadas de manera exitosa:

Tabla 32 - Resumen de resultados Tercer Objetivo

Tarea: Definir las métricas adecuadas para la evaluación de la estructura craneal Cavum Septum Pellucidum

Se definió que las métricas a usar son las siguientes:

- Para el primer caso no basaremos en el tamaño de la estructura por lo que las métricas a usar son el largo y el ancho.
- Para el segundo caso teniendo en cuenta que la revisión del experto determino que la mayoría son imágenes de casos normales, se determina tomas las medidas de alto, ancho, media, desviación estándar y variación para determinar la normalidad o anormalidad

Tarea: Calcular las métricas establecidas sobre las imágenes de ultrasonido recopiladas

Se generó una tabla de medidas o el cálculo del tamaño tal y como se pudo ver en las anteriores secciones de este capítulo.

Tarea: Establecer criterios que permitan determinar la normalidad o anormalidad dependiendo de las métricas calculadas

Debido a que no se puede determinar de manera certera los rangos de normalidad o anormalidad de la estructura se decide tomar dos posibles salidas:

- Definir la anormalidad por el tamaño de la estructura, es decir si el largo es un 30% más grande que el ancho será anormal, de lo contrario se determina normalidad.
- Otra definición fue llevada a cabo con nuestro experto el cual al revisar las imágenes del estudio determina que la mayoría pertenecen a casos de normalidad por lo que podemos generar una media para el largo o el ancho y usando la desviación estándar podremos determinar si es normal o anormal.

Tarea: Realizar pruebas y validación de los resultados generales

Se validó con nuestro experto y se llega a conclusión que las dos formas de determinación de la anormalidad o normalidad son posibles y viables.

8 CONCLUSIONES Y TRABAJOS FUTUROS

8.1 CONCLUSIONES

Al finalizar este proyecto podemos llegar a las siguientes conclusiones:

- Se determinó que el sistema permite a un especialista sin experiencia identificar el plano craneal con una precisión de 99%, esto garantiza que el proceso de lectura de las ecografías en 2D sea más sencillo de comprender así no se cuente con la mejor calidad de la imagen.
- Se identificó la estructura Cavum Septum Pellucidum con un poco más de 79 por ciento de precisión para el plano Trans-Thalamic, y para los casos de los planos Trans-Cerebellum y Trans-ventricular se llegó a un buen nivel de identificación de la estructura obteniendo una precisión de 85% y 84.9% respectivamente.
- Los modelos implementados dentro del trabajo tienen el potencial de mejorar la detección de anomalías. Además de reducir el tiempo en los diagnósticos, esto debido a que sería una tarea más automatizada que permitirá a los especialistas centrarse en la evaluación y validación de los dictámenes entregados por el sistema.
- Al permitir identificar una posible malformación de la estructura Cavum Septum Pellucidum se contribuye a una medicina preventiva y se brinda la oportunidad a los especialistas para mejorar la vida de los futuros recién nacidos, lo que podría afectar directamente las tasas de personas que sufran de enfermedades tales como holoprosencefalia, displasia septo-óptica o agenesia del cuerpo caloso.
- Otra de las conclusiones del proyecto permite identificar que se tendrá una reducción en temas importantes tales como disminución de errores humanos, mayor accesibilidad y decrecimiento dentro de la mortalidad infantil. Todos los anteriores aspectos se ven afectados debido a que el sistema posee buenos niveles de precisión y con un uso más constante e ingreso de mayor cantidad de imágenes de ultrasonido en 2D, tendrá un mejor desempeño, escalando hasta el punto de llegar a un grado de independencia que permita un mejor dictamen.
- En este momento no se posee una clara forma para la determinación del dictamen, pero el proyecto presenta dos posibles soluciones las cuales no están basadas en dimensiones numéricas si no en aspectos estructurales del Cavum Septum Pellucidum que permiten llegar a una posible solución al problema planteado en el objetivo general del proyecto.

Todas las anteriores conclusiones permiten evidenciar que el proyecto aplica de manera satisfactoria el aprendizaje profundo como una vía para el mejoramiento de los procesos tediosos en la medicina, tal y como lo es la lectura de imágenes de ultrasonido en 2D que en muchas ocasiones no son las mejores o más fáciles de interpretar debido a problemas físicos del paciente o tecnológicos. Todo lo anterior puede conllevar a errores en los dictámenes por parte del personal médico o a la pérdida de vidas humanas.

8.2 TRABAJOS FUTUROS

A lo largo del desarrollo del proyecto de grado se logró la generación de un sistema que permite la identificación del plano craneal del feto y adicionalmente el reconocimiento de la estructura Cavum Septum Pellucidum, estos procesos fueron realizados por medio de una VGG19 y de una U-net respectivamente. Todos los modelos utilizados tuvieron buenos rendimientos llegando desde 79% hasta un 99% de precisión. Es en este aspecto es donde se encuentra una posible mejora u otro posible trabajo que podría ser llevado a cabo por otro grupo de investigación que deseara profundizar en los procesos.

Para aclarar, uno de los posibles trabajos que se podrían generar a partir de este estudio es el mejoramiento del modelo de U-net que se usó para la identificación de la estructura craneal Cavum Septum Pellucidum. Esto se podría lograr al modificar el modelo existente o crea uno nuevo que se ajuste mejor a las necesidades de las imágenes. Este proceso podría conllevar a obtener una mayor cantidad de información y a un mayor proceso de lo cual podría ser llevado a cabo por un grupo de investigación que deseara profundizar en el tema.

Otro posible trabajo futuro sería en la implementación de este mismo sistema, pero solo teniendo en cuenta imágenes generadas por hospitales y clínicas colombianas. Este nuevo proyecto tendría un gran impacto en la comunidad local y estaría más enfocado en máquinas, procesos e instituciones colombianas, lo que brindaría un mayor beneficio.

Otra posibilidad que se presenta con este trabajo es la incursión en otras estructuras craneales para complementar el sistema de detección de anormalidad. Lo anterior permitirá al sistema tener más de una estructura para el análisis y garantizaría una evaluación más precisa del crecimiento del feto. Adicionalmente, mejoraría aspectos como confiabilidad e incertidumbre, esto debido a que en varios artículos se menciona que por sí solo el estudio del Cavum Septum Pellucidum no es suficiente para determinar una posible anormalidad.

Por último, otro posible trabajo sería la realización de un proceso más minucioso al momento de definir cómo se deben realizar las medidas de la estructura, esto implicaría un gran reto para un equipo de investigación que desee realizar este posible proyecto, esto se debe a los problemas que se presentan en estandarización y publicación de las medidas por parte de las instituciones médicas que realizan la toma de imágenes de ultrasonido.

9 REFERENCIAS BIBLIOGRÁFICAS

- [1] F. Maso, «<https://historia.nationalgeographic.com.es/>,» National Geographic, 09 Marzo 2023. [En línea]. Available: https://historia.nationalgeographic.com.es/a/el-nacimiento-de-la-medicina-en-mesopotamia-entre-la-magia-y-la-ciencia_19267. [Último acceso: 28 Noviembre 2023].
- [2] M. Águila Carbelo, L. Esquivel Sosa y C. Rodríguez González, «Historia y desarrollo del ultrasonido en la Imagenología,» *Acta Médica del Centro*, vol. 13, nº 4, pp. 601-615, 2019.
- [3] D. Guitierrez Coronado, I. Matas , E. CARne Bonet, E. Eixarch, E. Monterde, P. Traversi, E. Gratacós y X. Burgos-Artizzu, «Automatic Deep Learning-Based Pipeline for Automatic Delineation and Measurement of Fetal Brain Structures in Routine Mid-Trimester Ultrasound Images,» *Karger*, vol. 1, nº 1, pp. 1-11, 2023.
- [4] F. Q. Kareem1 y A. M. Abdulazez, «Ultrasound Medical Images Classification Based on Deep Learning Algorithms: A Review,» *Fusion: Practice and Applications*, vol. 3, nº 1, pp. 29-42, 2021.
- [5] Organización mundial de la Salud, «who.int,» Organización mundial de la Salud, 27 Febrero 2023. [En línea]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/birth-defects>. [Último acceso: 28 Noviembre 2023].
- [6] Organización Panamericana de Salud, «Organización Panamericana de Salud,» Organización Panamericana de Salud, 2 Marzo 2020. [En línea]. Available: <https://www.paho.org/es/noticias/3-3-2020-nacidos-con-defectos-congenitos-historias-ninos-padres-profesionales-salud-que>. [Último acceso: 4 noviembre 2023].
- [7] H. R. Torres, P. Morais, B. Oliveira, C. Birdir, M. Rüdiger, J. C. Fonseca y J. L. Vilaça, «A review of image processing methods for fetal head and brain analysis in ultrasound images,» *Computer Methods and Programs in Biomedicine*, vol. 1, nº 1, pp. 1-24, 2022.
- [8] T. Ciceri, L. Squarcina, A. Giubergia, A. Bertoldo, P. Brambilla y D. Peruzzo, «Review on deep learning fetal brain segmentation from Magnetic Resonance images,» *www.elsevier.com/locate/artmed*, vol. 143, nº 1, pp. 1-15, 2023.
- [9] S. Xiao, J. Zhang, Y. Zhu, H. Cao, M. Xie y L. Zhang, «Application and Progress of Artificial Intelligence in Fetal Ultrasound,» *journal of clinical medicine*, vol. 12, nº 3298, pp. 1-16, 2023.
- [10] M. Henderson y J. Dolan, «Challenges, solutions, and advances in ultrasound-guided regional anaesthesia,» *BJA Educations*, vol. 16, nº 11, pp. 374-380, 2016.
- [11] V. Anaya, P. Sartori, Y. Montenegro, M. Cayo y G. Barba, «Variantes anatómicas del septum pellucidum,» *Elsevier*, vol. 2, nº 70, pp. 80-85, 2015.
- [12] A. S. Ginsburg, Z. Liddy, P. T. Khazaneh, S. May y F. Pervaiz, «A survey of barriers and facilitators to ultrasound use in low and middle-income countries,» *nature portfolio*, vol. 13, nº 3322, pp. 1-11, 2023.
- [13] «Using deep-learning algorithms to classify fetal brain ultrasound images as normal or abnormal,» *Ultrasound Obstet Gynecol*, vol. 56, nº 1, pp. 579-587, 2020.
- [14] T. L. Szabo, *Diagnostic Ultrasound Imaging : Inside Out*, Boston: MatlabExamples, 2014.
- [15] National Institute Of Biomedical Imaging and Bioengineering, «National Institute Of Biomedical Imaging and Bioengineering,» NIBIB, 11 Noviembre 2023. [En línea]. Available: <https://www.nibib.nih.gov/espanol/temas-cientificos/ultrasonido>. [Último acceso: 11 Noviembre 2023].

- 2023].
- [16] Wikipedia, «Wikipedia,» Wikipedia, 24 Septiembre 2023. [En línea]. Available: <https://es.wikipedia.org/wiki/Ultrasonido>. [Último acceso: 11 Noviembre 2023].
- [17] J. E. Duque Parra, «Cavum Septum Pellucidum: Hallazgo Mediante Disección Neuroanatómica,» *International Journal of Morphology*, vol. 4, nº 30, pp. 1508-1511, 2012.
- [18] A. González-González, R. Rodríguez-González y B. Herrero-Ruiz, «Ecografía en obstetricia,» *Puesta al día en las técnicas*, vol. 7, nº 1, pp. 39-44, 2009.
- [19] R. Gonzalez y R. Woods, *Digital Image Processing*, New York: Pearson, 2018.
- [20] J. A. Viruez Soto, C. M. Vallejo Narváez, B. Zavala Barrios, Á. A. Pérez Calatayud, J. C. Briones Garduño, . M. A. Díaz de León Ponce y C. G. Briones Vega, «Ultrasonido en obstetricia crítica,» *Revista de la Asociación Mexicana de Medicina Crítica y Terapia Intensiva*, vol. 29, nº 1, pp. 32-37, 2015.
- [21] M. JARAMILLO ECHEVERI y V. OLASCUAGA ROMERO, «Universidad EEIA,» 01 enero 2022. [En línea]. Available: <https://repository.eia.edu.co/server/api/core/bitstreams/6254c859-968f-40cb-8e95-6998afb8672d/content?page=25&zoom=100,148,490>. [Último acceso: 18 Noviembre 2023].
- [22] J. A. LAGARES, N. DÍAZ-DÍAZ y C. D. BARRANCO GONZALEZ, «APRENDIZAJE PROFUNDO: UNA NUEVA VÍA PARA CONVERTIR EL DATO EN CONOCIMIENTO,» *Economía Industrial*, vol. 423, nº 1, pp. 25-38, 2022.
- [23] C. Véliz, *Aprendizaje automático. Introducción al aprendizaje profundo*, Lima: Fondo Editorial, 2020.
- [24] R. Sreelakshmy, A. Titus, N. Sasirekha, E. Logashanmugam, R. Benazir Begam, G. Ramkumar y R. Raju, «An Automated Deep Learning Model for the Cerebellum Segmentation from Fetal Brain Images,» *BioMed Research International*, vol. 1, nº 1, p. 13, 2022.
- [25] T. Bala Krishna y P. Kokil, «Standard fetal ultrasound plane classification based on stacked ensemble of deep learning models,» *Expert Systems with Applications*, vol. 238, nº 1, pp. 122-153, 2024.
- [26] S. Tuncer Can, H. Golbasi, . B. Bayraktar, C. Saglam, . I. Omeroglu, R. Torun, . I. Gercik, H. Ankara Aktas y A. Ekin, «Can cavum septum pellucidum width and length measurements also be reliable indicators of corpus callosum measurements in normal fetuses?,» *Wiley Periodicals LLC*, vol. I, pp. 1-9, 2024.
- [27] J. I. Rosenbloom, L. H. Yaeger y S. Porat, «Reference Ranges for Corpus Callosum and Cavum Septi Pellucidi Biometry on Prenatal Ultrasound,» *American Institute of Ultrasound in Medicine.*, vol. 41, pp. 2135-2148, 2022.
- [28] O. Shen, A. Gelot, M. Moutard, J. Jounnic, H. Sela y C. Garel, «Abnormal shape of the cavum septi pellucidi: an indirect sign of partial agenesis of the corpus callosum,» *Ultrasound Obstet Gynecol* , vol. 46, pp. 595-599, 2015.
- [29] P. Falco, S. Gabrielli, A. Visentin, A. Perolo, S. Pilu y L. Bovicelli, «Transabdominal sonography of the cavum septum pellucidum in normal fetuses in the second and third trimester of pregnancy,» *Ultrasound Obstet Gynecol*, vol. 553, nº 16, p. 549, 200.
- [30] A. Mahmood , A. Marco , M. Michel , A. Fatima , A. Khalid y H. Mowafa , «Large-scale annotation dataset for fetal head biometry in ultrasound images,» *Data In Brief*, vol. 51, nº 109408, pp. 1-11, 2023.