



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

FACULTAD DE INGENIERÍAS

“Sistema inteligente para detección de alteraciones neurológicas en lactantes.”

TESIS

QUE COMO PARTE DE LOS REQUISITOS PARA OBTENER EL GRADO DE:
MAESTRO EN CIENCIAS (MECATRÓNICA)

PRESENTA:

Salvador Calderón Uribe

DIRIGIDO POR:

Dr. Irving Armando Cruz Albarrán
Dr. Luis Alberto Morales Hernández



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

FACULTAD DE INGENIERÍAS
Maestría en Ciencias (Mecatrónica)

“Sistema inteligente para detección de alteraciones neurológicas en lactantes.”

TESIS

QUE COMO PARTE DE LOS REQUISITOS PARA OBTENER EL GRADO DE:

MAESTRO EN CIENCIAS (MECATRÓNICA)

PRESENTA:

Salvador Calderón Uribe

DIRIGIDO POR:

Dr. Irving Armando Cruz Albarrán

CO-DIRIGIDO POR:

Dr. Luis Alberto Morales Hernández

Dr. Irving Armando Cruz Albarrán

Presidente

Dr. Luis Alberto Morales Hernández

Secretario

Roque Alfredo Osornio Ríos

Vocal

Dr. Juan Primo Benítez

Suplente

Dr. Emmanuel Reséndiz Ochoa

Suplente

Dedicatoria

A mis padres Mario Calderón Gómez y Rosa María Uribe Zavala, quienes con su amor, paciencia y esfuerzo me han permitido alcanzar un objetivo más, gracias por inculcar en mi el ejemplo de perseverancia, esfuerzo y valentía.

A mis hermanos Mario Calderón Uribe y Uriel Calderón Uribe por siempre estar presentes brindándome su apoyo y cariño, por todos los momentos que hemos vivido juntos.

Agradecimientos

- Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico brindado durante la realización de este proyecto.
- A la Universidad Autónoma de Querétaro por permitirme formar parte de ella y abrirme sus puertas para poder realizar mis estudios de maestría.
- A mi asesor el Dr. Irving Armando Cruz Albarrán, por su apoyo y confianza, por ser quien me ha guiado a través de sus consejos y conocimientos en este trabajo de tesis y a lo largo de la carrera.
- Al Dr. Luis Alberto Morales Hernández, al Dr. Roque Alfredo Osornio Ríos y demás profesores que me brindaron sus conocimientos y apoyo para seguir adelante día a día.

Índice general

Resumen	3
Abstract	5
1. Introducción	6
1.1. Antecedentes	6
1.2. Descripción del problema	10
1.3. Justificación	12
1.4. Hipótesis	12
1.5. Objetivo General	13
1.6. Objetivo Particular	13
1.7. Planteamiento General	13
2. Revisión Literaria	15

ÍNDICE GENERAL

2.1. Estado del Arte	15
2.2. Marco Teórico	16
2.2.1. Imágenes de Resonancia Magnética (IRM)	16
2.2.2. Alteraciones Neurológicas en Lactantes	16
2.2.3. Ventriculos laterales	18
2.2.4. Preprocesamiento de Imágenes	20
2.2.5. Segmentación de Imágenes y Extracción de Características.	21
2.2.6. Normalización Estadística	29
2.2.7. Sistemas Inteligentes	30
2.2.8. Evaluadores de Desempeño	33
3. Metodología	34
3.1. Base de Datos	35
3.2. Selección de Imágenes de Resonancia Magnética	36
3.3. Preprocesamiento de Imágenes	37
3.4. Procesamiento de Imágenes	39
3.5. Segmentación de Imágenes	43
3.6. Extracción De Características	45
3.6.1. Matriz de Características.	46

ÍNDICE GENERAL

3.6.2. Normalización De Datos.	47
3.7. Diagnóstico Del Especialista (Clasificación De Los Pacientes)	47
3.8. Modelo de Clasificación	48
3.8.1. Regresión Logística.	49
3.8.2. Redes neuronales artificiales.	50
3.8.3. K-vecinos cercanos (K- nearest neighbor)	52
4. Resultados	53
4.1. Matriz de confusión de la regresión logística	53
4.2. Matriz de confusión de la red neuronal artificial	54
4.3. K-vecinos cercanos (K- nearest neighbor)	56
5. Conclusiones	58
5.1. Conclusiones generales	58
6. Prospectivas	60
Anexos	64

Índice de figuras

1.1. Planteamiento general del sistema.	14
2.1. Localización anatómica de las funciones cerebrales (Rebolledo, 2004).	17
2.2. Estudio de IRM para detección de alteraciones neurológicas (Romero-Guzman, 2019)	19
2.3. Resonancia magnética del daño cerebral perinatal. A) Ictus isquémico arterial B) Leucomalacia periventricular quística (LPV), C) Infarto hemorrágico periventricular y LPV quística. D) LPV quística. E) Hallazgos neurorradiológicos compatibles con LPV no quística. F) LPV quística y quiste parencefálico frontal izquierdo secundario a infarto hemorrágico periventricular (Hinojosa-Rodriguez <i>et al.</i> ,2020).	20
2.4. Técnicas de umbralización	22
2.5. (Izquierda) Distancia entre el punto a clasificar al conjunto de entrenamiento, (Derecha) Algoritmo KNN en dos dimensiones con $k = 3$	31
2.6. Diagrama de una red neuronal artificial.	32
3.1. Planteamiento general del sistema.	35

ÍNDICE DE FIGURAS

3.2. Selección de imágenes.	36
3.3. Preprocesamiento de imágenes: supresión de fondo	37
3.4. Preprocesamiento: a) Medición de anchura en zonas superior e inferior, b) Rotación de imágenes.	38
3.5. Preprocesamiento: a) Medición de anchura en zonas superior e inferior, b) Rotación de imágenes.	38
3.6. Obtención de histogramas, a) histograma del cuerpo posterior, b) histograma del cuerpo anterior.	39
3.7. Calculo automático del umbral: a) Representación del cuerpo posterior, b) Representación del cuerpo anterior.	40
3.8. Algoritmo Sobel: a) Representación de la magnitud de los contornos en el cuerpo posterior, b) Representación del contorno adquirido, c) Cuerpo posterior resultante.	41
3.9. Delimitación de ventrículos.	42
3.10. a) Delimitación mediante la posición central y el radio de los ventrículos, b) Región obtenida.	42
3.11. Selección de imágenes para extracción de características.	46
3.12. Representación de matriz de características, donde m es el numero total de pacientes y n el número total de características.	47
3.13. Metodología de distribución de datos y evaluación del modelo inteligente.	49
3.14. Proceso de entrenamiento de la red neuronal.	51
4.1. Matriz de confusión del conjunto de evaluación.	54

Índice de tablas

2.1. Trastornos neurológico según la función cerebral y su localización anatómica (Rebolledo, 2004).	18
2.2. Matriz de confusión para un problema de clasificación de dos clases.	33
3.1. Comparación de imágenes originales con respecto a las imágenes segmentadas.	45
3.2. Clasificación de los pacientes por el especialista.	48
3.3. Características del modelo de Regresión logística	50
3.4. Características del modelo de Red Neuronal	52
4.1. Indicadores de evaluación	57
4.2. Tiempo de ejecución	57

Resumen

La detección y diagnóstico de alteraciones neurológicas es considerada una de las tareas más desafiantes para un médico especialista, esto a causa de diversos factores como, la gran cantidad de información que debe ser comparada, los síntomas y localización de los distintos tipos de enfermedad, así como la interpretación que el especialista debe otorgar apoyándose de diagnósticos previos. Por ello, en los últimos años, áreas como el procesamiento digital de imágenes, la inteligencia artificial y la neurología, han colaborado entre si con el propósito de diseñar herramientas de asistencia médica. Sin embargo, aunque el desarrollo de estas herramientas ha ido creciendo en los últimos años, este se ha enfocado principalmente en la población adulta, debido a la maduración neurológica que presenta un paciente en esta etapa, así como la heterogeneidad que presentan sus estudios.

Por tal motivo, el presente trabajo tuvo como objetivo desarrollar e implementar un sistema inteligente basado en el procesamiento de imágenes de resonancia magnética (IRM) y algoritmos de inteligencia artificial para detectar la presencia de alteraciones neurológicas en pacientes lactantes. Este sistema se enfocó en el estudio de los ventrículos laterales de 72 pacientes con alteración neurológica y 17 pacientes sanos, de este modo el sistema utiliza herramientas de segmentación basadas en umbrales con el fin de identificar dichas regiones de interés, posteriormente se realizó la extracción de características basadas en la forma e intensidad de los ventrículos laterales con el objetivo de resaltar similitudes y diferencias entre pacientes. Finalmente se utilizaron modelos inteligentes para llevar a cabo la clasificación automática de los pacientes.

El estudio permitió determinar la efectividad de distintos algoritmos de clasificación, obteniendo como resultado una precisión superior al 90 % utilizando modelos de redes neuronales y una precisión superior al 70 % utilizando modelos de regresión logística.

ÍNDICE DE TABLAS

Con el desarrollo de este trabajo se presentó una técnica de detección de alteraciones neurológicas en lactantes que permite asistir al personal médico en la identificación de estas, permitiendo así realizar una intervención temprana y un abordaje multidisciplinario, favoreciendo el pronóstico de los pacientes lactantes.

Palabras Clave: IRM, Ventrículos laterales, Procesamiento de imágenes, Algoritmos inteligentes.

Abstract

The detection and diagnosis of neurological disorders is considered one of the most challenging tasks for a medical specialist, due to various factors such as, the large amount of information that must be compared, the symptoms and location of the different types of disease, as well as the interpretation that the specialist must give based on previous diagnoses. For this reason, in recent years, areas such as digital image processing, artificial intelligence and neurology have collaborated with each other to design healthcare tools. However, although the development of these tools has been growing in recent years, it has mainly focused on the adult population, due to the neurological maturation that a patient presents at this stage, as well as the heterogeneity of their studies.

For this reason, the present work aimed to develop and implement an intelligent system based on the processing of magnetic resonance images and artificial intelligence algorithms to detect the presence of neurological alterations in lactating patients. This system focused on the study of the lateral ventricles of 72 patients with neurological disorders and 17 healthy patients, in this way the system uses segmentation tools based on thresholds to be able to identify these regions of interest, later the extraction of characteristics based on the shape and intensity of the lateral ventricles in order to highlight similarities and differences between patients. Finally, intelligent models were used to perform the automatic classification of patients.

The study made it possible to determine the effectiveness of different classification algorithms, obtaining as a result an accuracy greater than 90% using neural network models and an accuracy greater than 70% using logistic regression models.

With the development of this work, a technique for detecting neurological alterations in infants was presented, which allows assisting medical personnel in their identification, thus

ÍNDICE DE TABLAS

allowing early intervention and a multidisciplinary approach, favoring the prognosis of infant patients.

Keywords: MRI, Lateral ventricles, Image processing, Intelligent algorithms.

Capítulo 1

Introducción

1.1. Antecedentes

Una de las tareas más desafiantes para un médico especialista en neurología pediátrica es la detección de alteraciones neurológicas en recién nacidos, debido a la habilidad y experiencia que este requiere para realizar la exploración del desarrollo neurológico, así como la capacidad para detectar de manera temprana una alteración del desarrollo en una población aparentemente normal. Según la Academia Mexicana de Neurología (2018) entre 2-5 % de los recién nacidos vivos tienen riesgo de daño neurológico, existiendo factores de riesgo prenatales, perinatales, postnatales y sociales, siendo el 55-75 % los daños ocurridos en el periodo perinatal y los recién nacidos pretérminos la población con mayor riesgo de sufrir problemas médicos y discapacidades neuroconductuales (Clark y Woodward, 2010; Taylor *et al.*, 2000), de los cuales según Peterson *et al.*, (2003) y Fraello *et al.*, (2011) el 47 % de ellos presentan posteriormente una parálisis cerebral, 27 % trastornos cognitivos y el 23 %-37 % trastornos sensoriales. Así mismo, existen diversos factores externos que generan alteraciones neurológicas, factores como, la nutrición deficiente, dificultad respiratoria, asfixia perinatal, Hiperbilirrubinemia (Vericat y Orden, 2017), falta de vitaminas esenciales (principalmente la vitamina B12) (Aguirre *et al.*, 2019), etc., que de no ser detectadas e intervenidas de manera temprana, pueden ser causa de anomalías funcionales y neurológicas, llegando a interferir en la capacidad social, mental y física de los infantes (Campos-Montero, 2009;

Wilson-Ching *et al.* 2013). Por ello, herramientas como la resonancia magnética (Parikh, 2019), la ultrasonografía cerebral convencional (USC), la técnica Doppler con imagen de flujo a color (DIFC) (López-Azorín *et al.*, 2012) y el electroencefalograma (EEG) (Hans y Tharp, 2005, Laureta *et al.*, 2012) han sido algunas de las herramientas de más amplio uso en la evaluación de los recién nacidos, Sin embargo, aun con estas técnicas, la detección y diagnóstico de estas enfermedades requiere de una gran labor por parte de los especialistas debido a los diferentes factores que deben ser tomados en cuenta, factores como la gran cantidad pacientes que deben ser observados por un solo especialista, la gran cantidad de imágenes que deben ser comparadas según el tipo de enfermedad, las características de dicha enfermedad, así como la interpretación que puedan dar los especialistas según los resultados obtenidos. Esta sobrecarga de trabajo es especialmente visible en países como México, donde tan solo en el 2018 México contaba con 1345 médicos especialistas en neurología (adultos y pediátrica), 18771 especialistas en pediatría y tan solo 610 especialistas en oncología (adultos y pediátrica)(Heinze *etal.*,2018), esta escasez de especialistas afecta seriamente la precisión y la fiabilidad de proporcionar interpretaciones y decisiones clínicas correctas a causa de la gran cantidad de pacientes observados por un solo experto. Debido a esto, y a la gran cantidad de información cuantificable que puede obtenerse de las señales e imágenes médicas, es necesario adaptar herramientas de diagnóstico asistido por computadora que permitan evaluar de una forma más rápida la condición del paciente a partir de imágenes médicas, proporcionando una evaluación no invasiva del desarrollo cerebral y la extensión de diversas lesiones cerebrales, ayudando no solo a comprender el alcance y el momento de la lesión, sino también a identificar a los bebés que pueden beneficiarse de una intervención temprana, minimizando el impacto de la lesión.

La resonancia magnética (RM) es una herramienta potente con alta sensibilidad para esbozar alteraciones, aspectos morfológicos y aspectos funcionales en el cerebro en desarrollo (Mathur y Inder, 2009; Ferrero-Montes, 2017), teniendo un nivel de sensibilidad mayor que la ecografía craneal para la detección de lesiones cerebrales en el lactante prematuro (Inder *et al.*, 2003; Grosse y Simeoni, 2012). Así mismo, las imágenes de RM son de gran utilidad para la detección y diagnóstico de diferentes alteraciones neurológicas y cerebrovasculares, alteraciones como el síndrome de encefalopatía posterior reversible (Gómez-Garza *et al.*, 2014), trastornos por déficit de atención (Moore *et al.*, 2012), trastorno del lenguaje (Moreno-Flagge, 2013), entre otros, además, tiene un valor pronóstico al detectar en forma temprana secuelas irreversibles como el infarto cerebral (Lamy *et al.*, 2004, Casey *et al.*, 2000, López-Azorín *et al.*, 2012, Pons *et al.*, 2009). Debido a dichas características, las

imágenes de resonancia magnética juegan un papel crucial en la detección, seguimiento e intervención oportuna de alteraciones neurológicas.

Por otro lado, en las últimas décadas el campo del procesamiento digital de imágenes (PDI) ha generado un gran impacto en diferentes ramas de la investigación. Gracias al desarrollo de tecnologías capaces de procesar una mayor cantidad de información, así como al desarrollo de la electrónica digital que permite la adquisición de imágenes de alta resolución, se ha podido llevar a cabo el desarrollo de técnicas aplicadas a imágenes digitales, esto, con la finalidad de cumplir con dos objetivos: Por un lado mejorar la calidad o facilitar la búsqueda de información que pueda ser interpretada por los humanos, y a su vez procesar los datos contenidos en un escenario a través de una máquina de percepción autónoma.

El desarrollo de estos dos objetivos se ha visto reflejado en diferentes ramas de la ciencia, tales como la cartografía en el procesamiento de imágenes satelitales (Buzai y Galban, 2020), ingeniería civil, para el análisis de pavimento y vialidades (Rodríguez y Arredonda, 2005; Ortiz *et al.*, 2019), para la detección automática de árboles y arbustos en fotografías aéreas de UAS (Garduño-Ramón *et al.*, 2014), y en la medicina, utilizado para detectar cambios sutiles pero de gran relevancia en imágenes médicas, cambios que a simple vista parecen imperceptibles, ocasionando que la detección y el diagnóstico de enfermedades se vuelva un proceso lento y propenso a errores humanos.

Debido al creciente desarrollo de técnicas para el procesamiento de imágenes, la medicina y la neurología se han apoyado de técnicas que le permitan segmentar información relevante en diferentes tipos de imágenes médicas (Jeyavathana *et al.*, 2016), por ejemplo, Senthilkumaran y Vaithegi (2016) propusieron la segmentación de imágenes médicas utilizando diferentes técnicas de umbralización, con la finalidad de evaluar el mejor desempeño de dichas técnicas, Sanchez & Vargas (2018), por su parte utilizan algoritmos de filtrado y umbralización para la identificación y clasificación de melanomas. Así mismo, dentro del área de la neurología, el PDI ha tomado gran relevancia ayudando en gran medida a la detección de diversas alteraciones neurológicas, por ejemplo, Steger y Sakas (2011) propusieron un método de segmentación interactiva a partir de imágenes médicas, adecuado para la detección de tumores esféricos. Letteboer *et al.* (2001) evaluaron el algoritmo *watershed* para la segmentación semiautomática y manual de tumores adquiridos por resonancia magnética, concluyendo que la segmentación semiautomática operada por un usuario experto en segmentar es de 2 a 5 veces más rápida que la segmentación realizada por un experto clínico. De igual forma, Ng *et al.* (2006) mejoró el método *watershed* y utilizó *K – Means Clustering* para mejorar la segmentación de imágenes por resonancia magnética, evitando

en gran medida la sobre-segmentación del algoritmo *watershed*. Isoglu *et al.* (2017), diseñaron también un algoritmo basado en $K - Means$ para localizar una o múltiples lesiones ocasionadas por esclerosis múltiple, a partir del análisis de imágenes de resonancia magnética. Por otro lado, Oishi *et al.* (2011) realizaron un atlas de contraste múltiple del cerebro neonatal humano, utilizando imágenes de resonancia magnética y técnicas de imágenes de tensor de difusión (*Diffusion tensor imaging*), Pisani *et al.*, (2014) diseñaron un equipo de diagnóstico automático y en tiempo real, capaz de reconocer convulsiones neonatales a partir de la adquisición de videos, extrayendo las señales de luminancia diferencial promedio de estos. Así mismo, al igual que el PDI, la inteligencia artificial (IA) ha llamado la atención en los últimos años, debido al desarrollo de máquinas que puedan imitar comportamientos inteligentes. Gracias a su gran versatilidad, el campo de la IA se ha dividido en diferentes áreas de estudio, tales como la robótica, el procesamiento de lenguaje natural (*natural language processing*) y el aprendizaje automático (*machine learning*), siendo este último un componente nuclear al relacionarse con las demás áreas.

A su vez, dentro del aprendizaje automático existen diferentes técnicas utilizadas para cubrir diferentes tipos de aplicaciones, por ejemplo, Sistemas de lógica difusa (Cruz-Albarran *et al.*, 2017), modelos de regresión (Mahmoud *et al.*, 2019), modelos de clasificación (Berón, 2020), redes neuronales, etc. Siendo las redes neuronales las más utilizadas en la actualidad debido a su capacidad para aprender información abstracta.

Actualmente el uso de la inteligencia artificial se ha extendido en diversos campos de la investigación, colaborando con diferentes tipos de herramientas que le permitan desarrollar capacidades de aprendizaje, siendo la detección de patrones y clasificación de imágenes digitales una de las tareas más importantes dentro de la IA, ya que, a partir del procesamiento y extracción de características de las imágenes, es posible clasificarlas en función de las características extraídas. Debido a la creciente colaboración entre el PDI y la IA, el área de la medicina y la neurología se han visto involucrada en el diseño de técnicas para la detección y diagnóstico de enfermedades de forma automática, esto, a partir del uso de técnicas del PDI para segmentar y extraer características relevantes de imágenes médicas, y a su vez, técnicas de IA para la detección y clasificación de dichas características, Somasundaram y Genish (2012), por ejemplo, realizaron una segmentación del Hipocampo a partir del uso de resonancia magnética, utilizando morfología matemática y lógica difusa. Dahab *et al.*, (2012) desarrollaron un detector automático de tumores cerebrales, utilizando métodos de detección de bordes para la segmentación de regiones de interés y redes neuronales probabilísticas. Shenbagarajan *et al.*, (2016), diseñaron también un algoritmo para el diagnóstico

de tumores cerebrales, utilizando modelos de contorno activo (*active contour models*) para la segmentación de imágenes, técnicas de extracción de características de textura y forma, y redes neuronales artificiales para la clasificación. Yang *et al.* (2018) por su parte diseñaron un clasificador de pacientes con migraña, utilizando como características de aprendizaje, imágenes por resonancia magnética funcional en estado de reposo, así como redes neuronales convolucionales para su clasificación, utilizando redes neuronales convolucionales basadas en el módulo inception. Por otro lado, Chowdhury *et al.*, (2011), diseñaron un modelo de red neuronal artificial para el diagnóstico de enfermedades neonatales utilizando diferentes algoritmos de entrenamiento.

Con base en lo anterior es posible observar que el uso de técnicas de inteligencia artificial y procesamiento de imágenes digitales son herramientas importantes para un especialista en medicina, debido a la alta velocidad con la que se procesa la información, así como la alta precisión que pueden obtener dichas herramientas en el diagnóstico y detección de ciertas alteraciones, logrando en algunos casos, una precisión en el diagnóstico superior al 85 % en la detección de tumores cerebrales en adultos, un 99.25 % en la detección de pacientes con migraña y un 75 % de precisión en el diagnóstico de enfermedades neonatales. Sin embargo, el uso de estas herramientas no ha sido llevado a cabo del todo en diversas áreas de la medicina, siendo la neurología pediátrica (o infantil) una de las áreas más escasas. Por ello, se propone el uso de técnicas de inteligencia artificial y procesamiento digital de imágenes de resonancia magnética para el desarrollo de un sistema inteligente para la detección de alteraciones neurológicas en lactantes.

1.2. Descripción del problema

Dentro de la neurología existen una variedad de herramientas que permiten al especialista realizar un diagnóstico sobre la salud del paciente, herramientas como, imágenes de resonancia magnética, electroencefalogramas, ultrasonografía cerebral convencional (USC), la técnica Doppler con imagen de flujo a color (DIFC) (López-Azorín *et al.*, 2012), etc. Sin embargo, aún con estas técnicas, la detección y diagnóstico de estas enfermedades requiere de una gran labor por parte de los especialistas, debido a factores que abarcan desde el proceso de adquisición de imágenes de resonancia magnética hasta la gran cantidad de imágenes que deben ser comparadas según el tipo de enfermedad y características de esta,

ocasionando que el diagnóstico recaiga en su totalidad en la perspectiva del médico, dando lugar a que posibles lesiones sean pasadas por alto o sean atendidas de forma errada debido a la complejidad de la enfermedad. Así mismo, el área de la neurología pediátrica supone un reto mayor, debido al rápido desarrollo neurológico en un recién nacido, así como la dificultad que supone detectar enfermedades en una población aparente sana. Del mismo modo, existe un porcentaje relativamente alto de (entre 2-5 %) recién nacidos vivos con riesgo de daño neurológico, siendo el 55-75 % los daños ocurridos en el periodo perinatal y los recién nacidos pretérminos la población con mayor riesgo de sufrir problemas médicos y discapacidades neuroconductuales. Sumado a esto, la adquisición y segmentación de imágenes por resonancia magnética llevada a cabo en recién nacidos se ve afectada por diferentes factores como son, los niveles similares de intensidad en la materia blanca y la materia gris al adquirir las imágenes de resonancia magnética (IMR) así como los tiempos que demora el tejido en recuperar el 63 % de la magnitud longitudinal y perder el 63 % de la magnetización transversal (T1 y T2 respectivamente), los cambios rápidos en los contrastes de T1 y T2, falta de contraste entre las estructuras cerebrales (Oishi *et al.*, 2011; Zhang *et al.*, 2015), artificios producidos por movimiento (respiración, latidos cardiacos, temblores, etc.) (Sánchez *et al.*, 2014; Sartori *et al.*, 2015), etc., lo que ocasiona una disminución en la calidad del examen al realizar el estudio con herramientas más costosas con el fin de llevar a cabo el diagnóstico.

Por otro lado, existe una escasa documentación enfocada al desarrollo de herramientas inteligentes que permitan ayudar a los médicos en la detección de alteraciones neurológicas en lactantes, ocasionando que el diagnóstico este sujeto únicamente al conocimiento empírico que poseen los especialistas, así como las interpretaciones que estos puedan dar. Así mismo, existen algunos estudios realizados mediante IRM y algoritmos de inteligencia artificial, sin embargo, la mayor parte de estos no están enfocados directamente al tratamiento de alteraciones neurológicas en los lactantes (Savasci *et al.*, 2019), sino únicamente al proceso de segmentación (Zhang *et al.*, 2015), o a la detección de enfermedades pero con hallazgos significativos muy limitados, lográndose en algunos trabajos una precisión en el diagnóstico inferior al 75 %, con un tiempo de procesamiento mayor a los 10 minutos y utilizando entornos comerciales (Matlab, MathWorks) para realizar el procesamiento de los datos y las aproximaciones (He *et al.*, 2018), Así mismo, estudios con una precisión en el diagnóstico superior al 75 % son llevadas a cabo utilizando diferentes señales médicas, señales de Electroencefalograma (Mizrahi y Kellaway, 1987) o cámaras termográficas (Savasci *et al.*, 2019), acompañados a su vez de softwares comerciales para realizar el estudio, elevando en

consecuencia los costos en la evaluación y posteriormente en el diagnóstico.

1.3. Justificación

La presente investigación se enfocará en llevar a cabo el proceso de detección de alteraciones neurológicas en lactantes a partir de un conjunto de imágenes obtenidas de una base de datos validada especialistas (ver anexo 1), esto con el fin de implementar una herramienta inteligente basada en el procesamiento de imágenes e inteligencia artificial, que permita evaluar la condición general del paciente de forma automática, ya que se considera que existe una limitada documentación enfocada a ayudar no solo a comprender el alcance y el momento de la lesión, sino también a identificar a los pacientes (bebés) que puedan beneficiarse de una intervención temprana, y a su vez, proponer una segunda opinión ante el diagnóstico de los o el especialista, basando su valoración en la interpretación de gran cantidad de información y características presentes en las imágenes, evitando que la carga recaiga completamente en la percepción y conocimiento del médico hacia una determinada afección. Así, el presente trabajo permitirá detectar alteraciones neurológicas en lactantes a partir de imágenes de resonancia magnética seleccionadas mediante software 3D Slicer, las cuales serán sometidas (empleando el software de código abierto Python) a un conjunto de procesos, tales como, filtrado, segmentación y extracción de características, lo que permitirá llevar a cabo el proceso de clasificación según la presencia de signos incipientes de alteraciones neurológicas, logrando así contar con un sistema inteligente basado en softwares libres que asista al especialista como una herramienta de apoyo y consulta en la detección de dichas alteraciones, y a su vez, proveer de una oportunidad para reducir el tiempo y costo que conlleva realizar el estudio.

1.4. Hipótesis

Mediante un sistema de inteligencia artificial se puede detectar alteraciones neurológicas en lactantes, utilizando algoritmos de segmentación y extracción de características en imágenes de resonancia magnética, reduciendo así el tiempo de procesamiento y el índi-

ce de error en la clasificación de imágenes diagnosticadas con la presencia de alteraciones neurológicas.

1.5. Objetivo General

Desarrollar e implementar un sistema inteligente basado en el procesamiento de imágenes de resonancia magnética y algoritmos de inteligencia artificial para detectar la presencia de alteraciones neurológicas en lactantes.

1.6. Objetivo Particular

- Implementar algoritmos de segmentación y extracción de características en IRM, tales como Umbralización OTSU, Detección de bordes, entre otras, con el fin de facilitar la separación entre las imágenes de pacientes con alteración neurológica y pacientes sin alteración neurológica.
- Diseñar un clasificador de las IRM basado en sistemas inteligentes (redes neuronales, KNN, entre otras) que permita maximizar la detección de alteraciones neurológicas.
- Llevar a cabo la integración de cada una de las etapas del sistema utilizando aquellas que permitan reducir el índice de error en la segmentación y clasificación de las IRM.
- Realizar un estudio para determinar la eficiencia del sistema utilizando algoritmos de evaluación y comparando los resultados con trabajos que utilicen una metodología similar.

1.7. Planteamiento General

El sistema estará basado en el diagrama de la figura 1.1, el cual, permite realizar cada una de las etapas mostradas en el sistema a partir de un conjunto de imágenes de resonancia

cia magnética obtenidas de una base de datos, inicialmente se lleva a cabo la selección de imágenes que muestran de una forma clara las regiones de las cuales un médico especialista se basa para la detección de alteraciones neurológicas, una vez seleccionadas las imágenes, la etapa del preprocesamiento permite eliminar imperfecciones que supondrán un inconveniente en futuros procesos, al limpiar la imagen, el proceso de segmentación y extracción de características resalta las diferencias que existen entre las diferentes clases con la finalidad de lograr la clasificación de dichas imágenes según la presencia de alteraciones neurológicas, finalmente el sistema será evaluado con el propósito de conocer el porcentaje de eficacia del sistema.

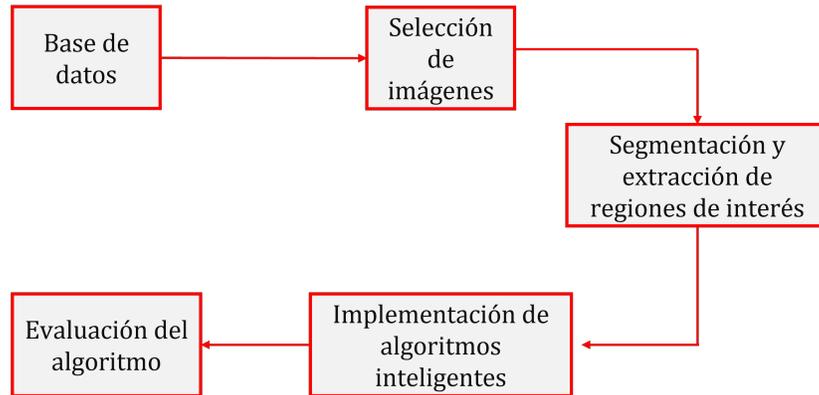


Figura 1.1: Planteamiento general del sistema.

Capítulo 2

Revisión Literaria

2.1. Estado del Arte

Durante los últimos años el uso del procesamiento digital de imágenes e inteligencia artificial han crecido considerablemente, colaborando en diversos estudios relacionados con la medicina y adentrándose en diferentes áreas de esta, por ejemplo, la cardiología, dermatología, pediatría, neurología, entre otras. Dicho crecimiento ha permitido generar modelos de investigación con los cuales la inteligencia artificial puede llevar a cabo el desarrollo de algoritmos que le permitan aprender a diferenciar y/o clasificar con cierto porcentaje de eficacia cada una de las muestras y características médicas.

Actualmente uno de los modelos más comunes utilizados por especialistas se basa en partir de la adquisición de muestras (imágenes o señales) las cuales son preprocesadas en un inicio con el fin de eliminar imperfecciones o ruido que supone una interferencia en la información, posteriormente las muestras son segmentadas para la extracción de información o características relevantes en las muestras, para de esta forma llevar a cabo la implementación del algoritmo de clasificación para cada una de las muestras (Dahab *et al.* , 2012; Savasci *et al.* , 2019). La implementación de este tipo de métodos permite maximizar la eficacia con la que se clasifica la información debido a cada una de las etapas que se llevan a cabo, logrando así sistemas un porcentaje de precisión mayor al 80% en diagnósticos.

2.2. Marco Teórico

2.2.1. Imágenes de Resonancia Magnética (IRM)

La imagen por Resonancia magnética es una técnica de diagnóstico que utiliza imanes y ondas de radio potentes para crear imágenes del cuerpo, caracterizadas principalmente por no usar radiaciones ionizantes, por proveer de una excelente resolución de contraste de los diferentes tejidos y resolución anatómica (Alvares, 2012), permitiendo así, obtener información de su composición. Las IRM son utilizada principalmente por radiólogos con la finalidad de visualizar la composición interna del cuerpo humano, principalmente para la evaluación del sistema nervioso central, incluyendo cualquier área del cerebro o columna vertebral, para la evaluación de tumores de cualquier tipo, para la evaluación de lesiones óseas o de músculos, etc. (Pons *et al.* , 2009). El desarrollo de la prueba consiste inicialmente en recabar información personal del paciente, así como adecuar al mismo para realizar la prueba, la cual suele tener una duración de entre 20 y 60 minutos. Alrededor de la zona del cuerpo a estudiar, se suele colocar aparatos cuya finalidad es mejorar la calidad de las imágenes que se desean obtener. Para pacientes que sufren de claustrofobia es posible necesitar algún sedante para realizar el estudio. Una vez obtenidos los resultados se obtienen varios conjuntos de imágenes, entre los cuales están las imágenes en secuencia potenciada en T1 y T2. Por último, un médico especialmente capacitado para interpretar las imágenes por resonancia magnética (radiólogo) analizará las imágenes de la gammagrafía e informará los resultados al médico especialista.

2.2.2. Alteraciones Neurológicas en Lactantes

Las alteraciones neurológicas son enfermedades del sistema nervioso central y periférico, es decir, del cerebro, la medula espinal, los nervios craneales y periféricos, etc. Una de las poblaciones más vulnerables y con más complicaciones en el diagnóstico y detección de estas alteraciones son los recién nacidos, debido a que existen diferentes factores externos que pueden generar el desarrollo de alteraciones neurológicas, factores como, la prematuridad, la nutrición deficiente, dificultad respiratoria, asfixia perinatal, Hiperbilirrubinemia, hipotiroidismo congénito, diabetes gestacional (Vericat y Orden., 2017), falta de vitaminas

esenciales (principalmente la vitamina B12) (Aguirre *et al.* , 2019), etc. Ocasionalmente diversos daños que pueden a su vez ser congénitos, propios de problemas dados durante el embarazo o el parto; o adquiridos, que son los posteriores al nacimiento, daños como: tumor cerebral, convulsiones, ictus, epilepsia, hidrocefalia, traumatismo craneoencefálico, etc. (Vericat & Orden., 2017). Sin embargo, gracias al uso de imágenes por resonancia magnética es posible realizar estudios cuantitativos in vivo del desarrollo del cerebro durante la infancia, permitiendo así tener una localización anatómica de las funciones cerebrales, y a su vez, las alteraciones relacionadas a dichas funciones (Tabla 2.1, figura 2.1) (Rebolledo, 2004), lo que permite asociar la afección según la zona en la que se encuentre la alteración.

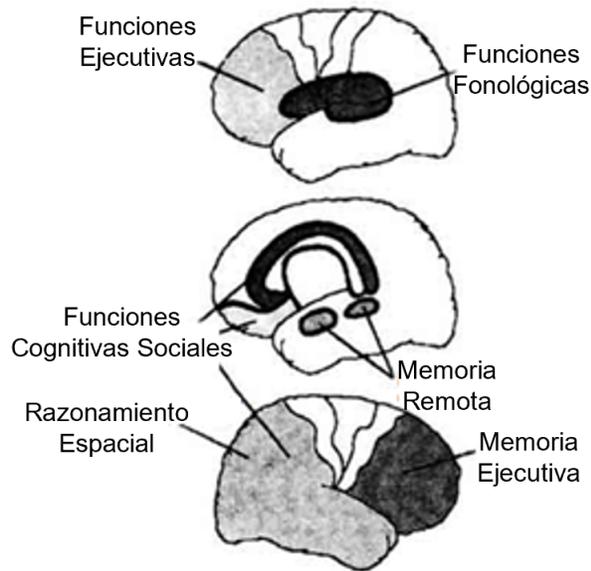


Figura 2.1: Localización anatómica de las funciones cerebrales (Rebolledo, 2004).

Función	Localización	Transtorno
Procesamiento fonológico	Región perisilviana izquierda	Dislexia
Funciones Ejecutivas	Prefrontal	Síndrome disejecutivo, déficit de atención.
Cognición espacial	Región posterior del hemisferio derecho	Déficit visuoespacial, disgrafía, discalculia.
Cognición Social	Sistema límbico. Región orbitaria, hemisferio derecho	Trastorno de conducta Espectro autista.
Memoria a largo plazo	Hipocampo y amígdala bilateral	Trastorno de memoria

Tabla 2.1: Transtornos neurológico según la función cerebral y su localización anatómica (Rebolledo, 2004).

2.2.3. Ventriculos laterales

La detección y el diagnóstico de alteraciones en ventrículos laterales (figura 2.2) se basa en los estudios de imagen de resonancia magnética, debido a que tienen una mayor sensibilidad y especificidad para la detección de las lesiones cerebrales lo que permite realizar una mejor caracterización de estas (Romero-Guzman,2019).

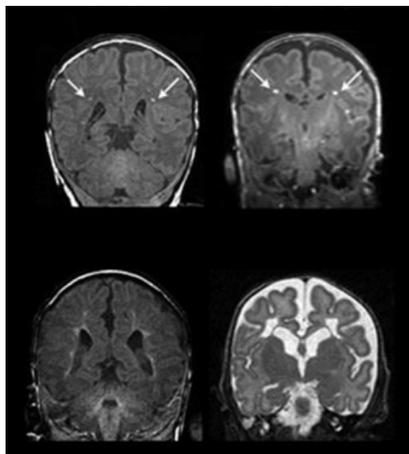


Figura 2.2: Estudio de IRM para detección de alteraciones neurológicas (Romero-Guzman, 2019)

Así mismo, el estudio de los ventrículos laterales es considerado uno de los estudios más importantes ya que otorga información sobre el desarrollo neurológico, siendo a su vez una región de interés debido a que múltiples patologías pediátricas como la Leucomalacia Periventricular (LPV), la Hemorragia de la matriz Germinal (HMG) y el Infarto Hemorrágico Periventricular (IHP) presentan alteraciones en la región peri-ventricular (figura 2.3) (Martínez-Biarge *et al.*, 2016, Hinojosa-Rodríguez *et al.*, 2020).

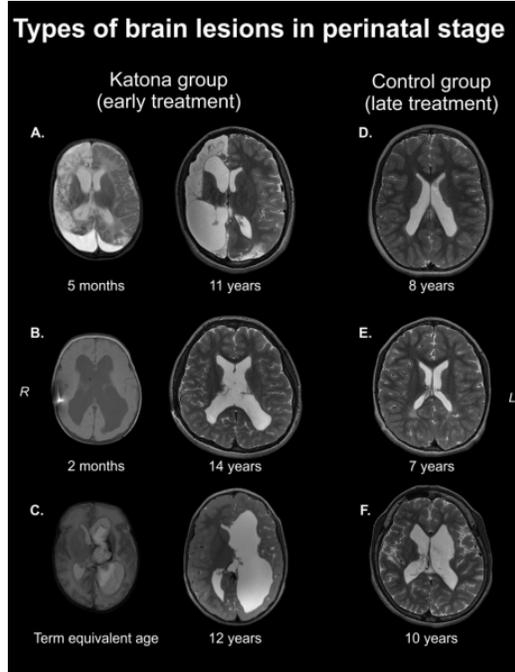


Figura 2.3: Resonancia magnética del daño cerebral perinatal. A) Ictus isquémico arterial B) Leucomalacia periventricular quística (LPV), C) Infarto hemorrágico periventricular y LPV quística. D) LPV quística. E) Hallazgos neurorradiológicos compatibles con LPV no quística. F) LPV quística y quiste parencefálico frontal izquierdo secundario a infarto hemorrágico periventricular (Hinojosa-Rodríguez *et al.*,2020).

2.2.4. Preprocesamiento de Imágenes

2.2.4.1. Filtro de Suavizado Gaussiano

El filtro Gaussiano definido mediante la ecuación 2.1, es utilizado para eliminar ruido, disminuir la nitidez y producir un suavizado más uniforme que el de la media (Dahab *et al.*, 2012).

$$G(x, y) = \frac{1}{c} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.1)$$

Donde x es la posición en el eje horizontal, y es la posición en el eje vertical, σ es la desviación estandar de la distribución gaussiana y $c = \sqrt{2\pi\sigma^2}$.

2.2.5. Segmentación de Imágenes y Extracción de Características.

2.2.5.1. Umbralización

Es una de las técnicas más importantes en la segmentación de imágenes, ya que, permite seleccionar un óptimo valor de umbral de los niveles de gris, separando los objetos de interés con respecto al fondo (Milstein, 1998). Esta técnica puede expresarse mediante la ecuación 2.2.

$$f(x, y) = \begin{cases} 1 & H(x, y) \geq T \\ 0 & H(x, y) < T \end{cases} \quad (2.2)$$

Donde $H(x, y)$ es la imagen de entrada, T es el umbral definido y $f(x, y)$ es la imagen binaria.

Dentro de estas técnicas, la umbralización automática se clasifica según la zona de este (global y local), figura 2.4. Donde un umbral global selecciona un único valor del histograma total de la imagen, donde su resultado depende de una iluminación uniforme, y los umbrales locales por otro lado, utilizan información de los niveles para elegir varios valores de umbral, cada uno optimizado para una región de la imagen (Ng, 2006). Entre las técnicas de umbralización global, Sahoo *et al.* (1988) concluyó que el método Otsu (Otsu, 1979) era uno de los mejores métodos de selección de umbral para imágenes generales del mundo real con respecto a las medidas de uniformidad y forma. Este método selecciona valores de umbral que maximizan las variaciones entre clases del histograma. El método Otsu es óptimo para umbralizar objetos grandes del fondo; en otras palabras, es bueno para umbralizar un histograma con distribución bimodal o multimodal, sin embargo, falla si el histograma es unimodal o cercano a unimodal.

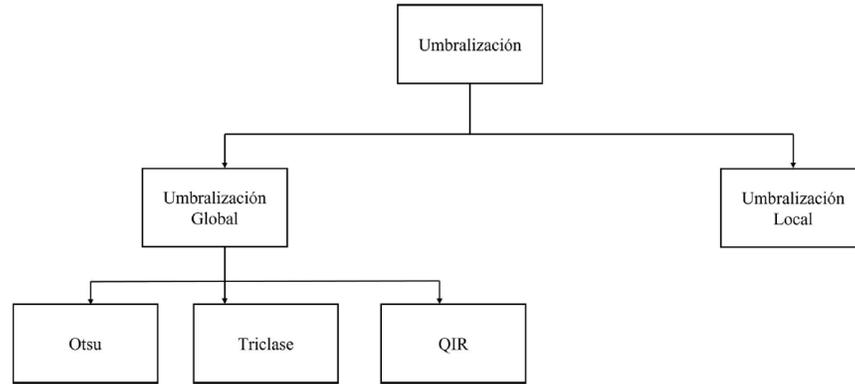


Figura 2.4: Técnicas de umbralización

2.2.5.2. Detección de Bordes.

La mayoría de los métodos de detección de bordes funcionan asumiendo que el borde se produce cuando hay una discontinuidad en la función de intensidad o un gradiente de intensidad muy pronunciado en la imagen. A partir de esta suposición, si se toma la derivada del valor de intensidad de la imagen y encuentra puntos donde la derivada es máxima, entonces el borde podría detectarse (Vincent & Folorunso, 2009). El gradiente es un vector, cuyos componentes miden que tan rápido cambia el valor de los píxeles con la distancia en las direcciones x e y . Por lo tanto, los componentes del gradiente pueden ser encontrados mediante las ecuaciones 2.3 y 2.4.

$$\frac{\delta f(x, y)}{\delta x} = \Delta x = \frac{f(x + dx, y) - f(x, y)}{dx} \quad (2.3)$$

$$\frac{\delta f(x, y)}{\delta y} = \Delta y = \frac{f(x, y + dy) - f(x, y)}{dy} \quad (2.4)$$

Donde dx y dy miden la distancia a lo largo de las direcciones x e y respectivamente. En términos de imágenes discretas, esta distancia puede traducirse como el número de píxeles que existen entre dos puntos de la imagen. Ya que $dx = dy = 1$ es la distancia mínima en

una imagen, por lo que las ecuaciones 2.3 y 2.4 pueden describirse como 2.5 y 2.6.

$$\Delta x = f(x + dx, y) - f(x, y) \quad (2.5)$$

$$\Delta y = f(x, y + dy) - f(x, y)dy \quad (2.6)$$

De este modo, para detectar la presencia de una discontinuidad de gradiente se calcula el cambio en el gradiente (x, y) mediante la medida de la magnitud definida por 2.7.

$$M = \sqrt{\Delta x^2 + \Delta y^2} \quad (2.7)$$

Y el gradiente de dirección θ se define mediante 2.8.

$$\theta = \tan^{-1}\left(\frac{\Delta x}{\Delta y}\right) \quad (2.8)$$

2.2.5.3. Operador Sobel

El operador Sobel es un operador de diferenciación discreto, que calcula una aproximación del gradiente de la función de intensidad de imagen (Sobel y Feldman, 1968). Los operadores de la ecuación 2.9 y 2.10 corresponden al kernel con el que se convolucionan la imagen de entrada (Vincent y Folorunso, 2009).

$$\Delta x = \begin{bmatrix} -1 & 1 \\ 0 & 0 \end{bmatrix} \quad (2.9)$$

$$\Delta y = \begin{bmatrix} -1 & 0 \\ 1 & 0 \end{bmatrix} \quad (2.10)$$

2.2.5.4. Operadores Morfológicos

Los operadores morfológicos se basan en operaciones de teoría de conjuntos, las cuales, utilizan componentes denominados elementos estructurantes, definido en su mayoría mediante la ecuación 2.11. Los dos principales operadores morfológicos llamados erosión

y dilatación los cuales permiten reducir el tamaño de la región de interés eliminando pequeños detalles de una imagen y expandir las formas contenidas en una imagen de entrada (Jeyavathana, *et al.*, 2016). Las ecuaciones 2.12 y 2.13 definen la operación de erosión y dilatación.

$$S = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.11)$$

$$f(x, y) = I(x, y) \ominus S \quad (2.12)$$

$$f(x, y) = I(x, y) \oplus S \quad (2.13)$$

Donde $I(x, y)$ es la imagen de entrada, S es el elemento estructurante y \ominus, \oplus son los operadores de erosión y dilatación respectivamente.

Así mismo, estos operadores se unen para formar diferentes maneras de procesar la imagen. Por ejemplo, la apertura morfológica formada de una erosión seguida de una dilatación utilizando el mismo elemento estructurante en ambas operaciones, y la operación de cerradura morfológica formada de una dilatación seguida de una erosión (Zhang *et al.*, 2019). Las ecuaciones 2.14 y 2.15 definen las operaciones de apertura y cerradura respectivamente.

$$f(x, y) = I(x, y) \circ S = (I(x, y) \ominus) \oplus S \quad (2.14)$$

$$f(x, y) = I(x, y) \cdot S = (I(x, y) \oplus) \ominus S \quad (2.15)$$

Donde \circ, \cdot son los operadores de apertura y cerradura respectivamente.

2.2.5.5. Área

Se refiere al área de la figura encerrada por la línea de contorno, que para una imagen bidimensional representa el número de píxeles diferentes a cero en la imagen a través de la fórmula de Green:

Sean M y N funciones de las dos variables x, y tales que sus primeras derivadas parciales son continuas en un disco abierto B de \mathbb{R}^2 . Si C es una curva cerrada, simple y suave a

trozos contenida completamente en B , y si R es la región limitada por C , entonces (Leithold, 1987)

$$\oint_L = M(x, y)dx + N(X, y)dy = \iint_R = \left(\frac{\delta N}{\delta x} - \frac{\delta M}{\delta y}\right)dA \quad (2.16)$$

De esta forma para el área de la región D que es $\iint_R dA$ para una imagen binarizada, el área está dada por la ecuación 2.17,

$$A = \sum_{x,y \in R} I(x, y) \quad (2.17)$$

También llamada fórmula de Green discreta, $I(x, y)$ es el valor del píxel en la x -ésima fila y y -ésima columna de la imagen. En el caso de ser una imagen binaria, $I(x, y)$ (valores de 0 o 1), el área encerrada dentro del contorno tendrá pixeles de valor uno y el área resulta un conteo de pixeles de valor 1 (Ramírez-Pérez, 2020; Mery, 2015).

2.2.5.6. Perímetro

El perímetro se define como el número de pixeles que pertenecen al límite de la de imagen o línea de contorno, para una imagen binarizada el perímetro esta dado por la ecuación 2.18,

$$L = \sum_{x,y \in l} I(x, y) \quad (2.18)$$

Donde l es el contorno de la imagen y L el valor del perímetro.

2.2.5.7. Redondez

Las características de forma suelen ser coeficientes sin unidades. Un ejemplo es la redondez, definida mediante la ecuación 2.19.

$$R = \frac{4A\pi}{L^2} \quad (2.19)$$

Donde A es el área de la figura, y L el perímetro. La redondez R es un valor entre 1 y 0, donde $R = 1$ es un círculo, y $R = 0$ es una región sin un área.

2.2.5.8. Análisis De Región Basado En Momentos

Centro de masa

El análisis de región basado en momentos es una herramienta que permite conocer características geométricas de una región, dichas características proveen información de la localización, tamaño y forma de una región segmentada (Klette, 2014).

Suponiendo una región R de pixeles localizados en una imagen I , los momentos (m) se definen mediante la ecuación 2.20,

$$m_{rs} = \sum_{x,y \in R} i^r j^s I(x, y) \quad (2.20)$$

Donde $r, s \in \mathbb{N}$ y su suma ($r + s$) define el orden del momento, de este modo es posible observar que el momento 0 definido en la ecuación 2.21 es igual al área de la región, así como también, el centro de masa de la región es posible definirlo mediante la ecuación 2.22, donde \bar{i} y \bar{j} definen las coordenadas en las que se encuentra el centro de masa.

$$m_{00} = \sum_{x,y \in R} i^0 j^0 \quad (2.21)$$

$$\bar{i} = \frac{m_{10}}{m_{00}} \quad \bar{j} = \frac{m_{01}}{m_{00}} \quad (2.22)$$

Sin embargo, el centro de masa y los momentos estadísticos de orden superior no son invariantes con la ubicación de la región. Esto puede ser útil para detectar objetos que deben estar en determinadas ubicaciones. De este modo, cuando los objetos de interés pueden estar en todas partes en la imagen, es posible utilizar características que sean invariantes a la posición. Usando el centro de masa, se definen los momentos centrales invariantes a la posición ($\mu_{r,s}$) como se muestra en la ecuación 2.23.

$$\mu_{r,s} = \sum_{x,y \in R} (i - \bar{i})^r (j - \bar{j})^s \quad (2.23)$$

2.2.5.9. Momentos de Hu

También conocidos como momentos centrales normalizados (2.24) son herramientas que brindan la misma información de la imagen que los momentos centrales (análogamente a como sucede en 2.20), también son invariantes bajo traslaciones, y además invariantes bajo escalamiento, es decir, realizando “acercamientos” y “alejamientos” de la figura a medir se obtienen los mismos valores.

$$n_{r,s} = \frac{\mu_{rs}}{\mu_{00}^{\frac{r+s}{2}+1}} \quad (2.24)$$

Con este tipo de construcción es posible encontrar momentos de manera que mantengan la información de (2.24) (invariantes a la traslación y escalamiento), pero que sus propiedades se amplíen a una invarianza para rotaciones y reflexiones. A estos momentos h_n se les conoce como momentos de Hu (Li, 2010) definidos mediante las ecuaciones (2.25-2.31).

$$h_0 = n_{2,0} + n_{0,2} \quad (2.25)$$

$$h_1 = (n_{2,0} + n_{0,2})^2 + 4n_{1,1}^2 \quad (2.26)$$

$$h_2 = (n_{3,0} - 3n_{1,2})^2 + (3n_{2,1} - n_{0,3})^2 \quad (2.27)$$

$$h_3 = (n_{3,0} + n_{1,2})^2 + (n_{2,1} + n_{0,3})^2 \quad (2.28)$$

$$h_4 = (n_{3,0} - 3n_{1,2})(n_{3,0} - 3n_{1,2})[(n_{3,0} - 3n_{1,2})^2 - 3(n_{2,1} + n_{0,3})^2] + (3n_{2,1} - n_{0,3}) + [3(n_{3,0} + n_{1,2})^2 - (n_{2,1} + n_{0,3})^2] \quad (2.29)$$

$$h_5 = (n_{2,0} + n_{0,2})^2[(n_{3,0} + n_{1,2})^2 - (n_{2,1} + n_{0,3})^2 + 4n_{1,1}(n_{3,0} + n_{1,2})(n_{2,1} + n_{0,3})] \quad (2.30)$$

$$h_6 = (3n_{2,1} - n_{0,3})(n_{2,1} + n_{0,3})[3(n_{3,0} + n_{1,2})^2 - (n_{2,1} + n_{0,3})^2] - (n_{3,0} - 3n_{1,2})(n_{2,1} - n_{0,3})[3(n_{3,0} + n_{1,2})^2 - (n_{2,1} + n_{0,3})^2] \quad (2.31)$$

2.2.5.10. Extensión Ventricular

Se define como la proporción del área del contorno respecto al área del rectángulo delimitador.

$$E = \frac{A}{A_d} \quad (2.32)$$

Donde A_d es el área del rectángulo delimitador

2.2.5.11. Valor Medio de Gris

Para imágenes en escala de grises, por ejemplo, imágenes de resonancia magnética el valor medio de gris de la región de interés (calculada mediante 2.33) proporciona información sobre la intensidad de una región (Mery, 2015).

$$G = \frac{1}{A} \sum_{x,y \in R} I(x, y) \quad (2.33)$$

Donde R es la región de interés, A es el área de dicha región y G es el valor medio de gris.

2.2.5.12. Nivel de Contraste

El contraste indica la diferencia en el valor de gris entre la región de interés y su vecindad. Cuanto menor sea la diferencia del valor de gris, menor será el nivel de contraste. El nivel de contraste se calcula mediante la ecuación 2.34 (Mery, 2015).

$$K = \frac{G - G_e}{G_e} \quad (2.34)$$

Donde G y G_e es el valor medio de gris (2.33) de la región de interés y la vecindad respectivamente.

2.2.6. Normalización Estadística

La normalización estadística es la transformación de escala de la distribución de una variable con el fin de realizar comparaciones respecto a conjuntos de elementos de distintas variables y distintas unidades de medida.

2.2.6.1. Normalización Min-Max.

La normalización Min-Max, definida mediante 2.35, permite trasladar el rango del conjunto de datos D a un único rango de valores de $[0, 1]$

$$D_{norm} = \frac{D - D_{min}}{D_{max} - D_{min}} \quad (2.35)$$

Donde D_{norm} es el conjunto de datos normalizados, D es el conjunto de datos de entrada y D_{max} y D_{min} son los valores máximo y mínimo del conjunto de datos D .

2.2.7. Sistemas Inteligentes

2.2.7.1. Regresión Logística.

La regresión logística es una herramienta estadística, utilizada principalmente para la predicción de datos (Dreiseitl & Ohno-Machado, 2002). Similar a un modelo de regresión lineal, el modelo de regresión logística es utilizado para los casos en los que se desea predecir la presencia o ausencia de una característica (Chitarroni, 2002), la ecuación 2.36 representa el modelo de regresión logística para una única variable independiente (Llaugel, & Fernández, 2011).

$$P = \frac{1}{1 + e^{-(\alpha + \beta x)}} \quad (2.36)$$

Donde α y β son los parámetros del modelo, x es la variable independiente, siendo $x \in [-\infty, \infty]$ y P es la predicción que del modelo, siendo $P \in [0, 1]$. Por otro lado, para el caso donde se tienen múltiples variables independientes, la regresión logística se define mediante la ecuación 2.37.

$$P = \frac{1}{1 + e^{-(\alpha + \sum_{i=1}^n \beta_i x_i)}} \quad (2.37)$$

2.2.7.2. Algoritmo de K vecinos más próximos (K-Nearest Neighbor)

El algoritmo $k - NearestNeighbor$ (Knn) es un enfoque no paramétrico, en el que se determinan las K muestras de entrenamiento más similares a un vector de características de prueba. La clase asignada es la clase más frecuente de esas K muestras. En otras palabras, en el conjunto de entrenamiento encontramos los K vecinos más cercanos de X y evaluamos el voto mayoritario de sus clases. Para clasificar, utiliza el cálculo de las distancias (por ejemplo, la distancia euclidiana) con la que establece cada una de las distancias entre el punto a clasificar y todos los puntos del conjunto de entrenamiento. Al obtener el valor de cada una de las distancias se determinan los k vecinos más cercanos y, según el tipo de la clase para determinar, asigna el punto a una de ellas (Rodríguez-Vázquez *et al.*, 2016) (figura 2.5).

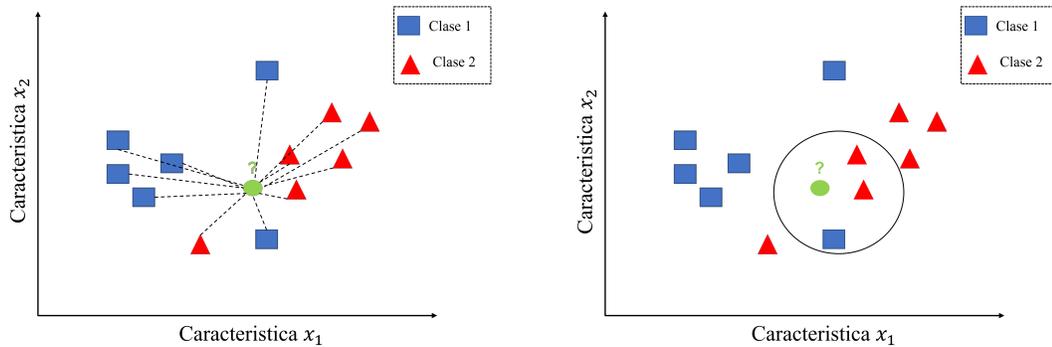


Figura 2.5: (Izquierda) Distancia entre el punto a clasificar al conjunto de entrenamiento, (Derecha) Algoritmo KNN en dos dimensiones con $k = 3$.

2.2.7.3. Redes Neuronales Artificiales (Artificial Neural Networks)

Las redes neuronales (NN) son ampliamente utilizadas en el proceso de clasificación de patrones, debido a que no requieren de ningún detalle con respecto a la distribución de probabilidad y las probabilidades a priori de varias clases. Con la finalidad de clasificar conjuntos de datos como lo son las imágenes, el método de las redes neuronales utiliza algoritmos como el de retro-propagación (*Back – propagation*), con la finalidad de categorizar las entradas en la colección de categorías objetivo de acuerdo con los parámetros de extracción de características, por lo que una red neuronal de retro-propagación (BPNN) es un método de aprendizaje supervisado que es una generalización no lineal del descenso del gradiente del error cuadrático, cuya finalidad es la de actualizar los pesos de las neuronas artificiales (Shenbagarajan *et al.* ; 2016; Charfi *et al.* 2014).

En general, una ANN se puede definir como un sistema o modelo matemático que consta de muchas neuronas artificiales no lineales que funcionan en paralelo y se pueden generar como una capa o multicapa, caracterizándose la mayoría de las ANN por tener tres capas: entrada, salida y oculta (figura 2.6), donde la función de la capa oculta es la de intervenir entre la entrada externa y la salida de la red de alguna manera útil.

Para una red neuronal multicapa de alimentación directa (FFNN), el modelo matemático que definen a la señal de salida (Y) y al error (E) se describen mediante las ecuaciones 2.38

y 2.39, respectivamente.

$$Y = F_0 \sum_{j=0}^M W_{0j} (F_h \sum_{i=0}^N W_{ji} X_i) \quad (2.38)$$

Donde W_{0j} representa los pesos sinápticos de la neurona Y la capa oculta a la neurona de salida única. X_i representa el i -ésimo elemento de la señal de entrada, F_h y F_0 son las funciones de activación de las neuronas de la capa oculta y de la capa de salida, respectivamente. W_{ji} la conexión entre los pesos y las neuronas de la capa oculta y de las entradas.

$$E = \frac{1}{2} \sum_{i=1}^m (Y_i - d_i)^2 \quad (2.39)$$

Donde Y_i es la señal de salida calculada por la red y d_i la salida esperada. Una vez que el error entre la salida de la red y la salida deseada sea mínimo, el proceso de aprendizaje finaliza y la red puede ser usada en una fase de evaluación (Charfi *et al.*, 2014).

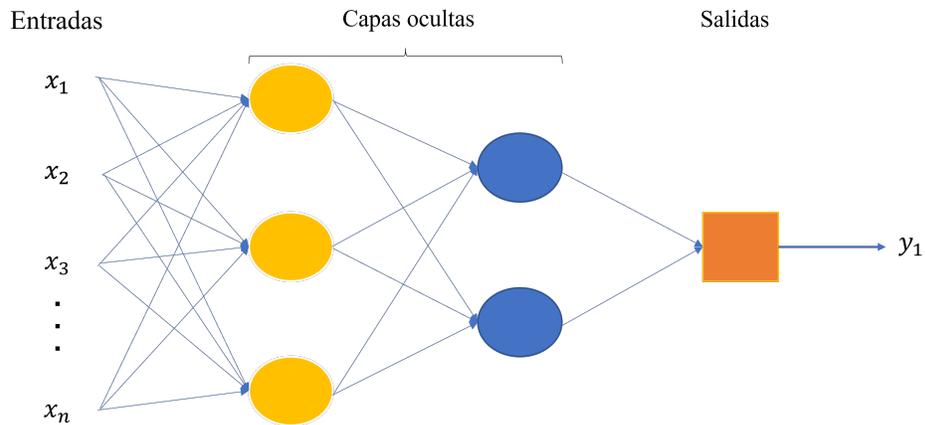


Figura 2.6: Diagrama de una red neuronal artificial.

2.2.8. Evaluadores de Desempeño

2.2.8.1. Matriz de Confusión

La matriz de confusión es una herramienta que permite observar el cumplimiento de un algoritmo que se utiliza en aprendizaje supervisado (Xu *et al.*, 2020). Cada columna de una matriz de confusión representa los resultados de la clase de predicción y las filas representan los resultados reales de la clase. Por ejemplo, una matriz de confusión de tamaño $n \times n$ asociada con un clasificador muestra la clasificación prevista y real, donde n es el número de clases diferentes. La tabla 2.2 muestra una matriz de confusión para $n = 2$, cuyas entradas tienen los siguientes significados.

- a es el número de predicción negativas correctos.
- b es el número de predicciones positivos incorrectas.
- c es el número de predicciones negativas incorrectas.
- d es el número de predicciones positivas correctas.

	Negativo predicho	Positivo predicho
Negativo Actual	a	b
Positivo Actual	c	d

Tabla 2.2: Matriz de confusión para un problema de clasificación de dos clases.

De este modo la precisión de la predicción y el error de la clasificación se pueden obtener mediante las ecuaciones 2.40 y 2.41 respectivamente.

$$Precision = \frac{a + b}{a + b + c + d} \quad (2.40)$$

$$Error = \frac{b + c}{a + b + c + d} \quad (2.41)$$

Capítulo 3

Metodología

Para el desarrollo del algoritmo se utilizó el software python 3.8 así como de las librerías Opencv 4.4.0.44 y scikit-learn 1.0.2, dicho algoritmo se basó en la estructura del diagrama de la figura 1, el cual, a partir de un conjunto de imágenes de resonancia magnética conformado por 17 pacientes sanos y 72 pacientes con afecciones neurológicas, permite realizar el proceso de segmentación de regiones de interés (ventrículos laterales), así como la detección de pacientes lactantes que presenten signos incipientes de alteraciones neurológicas.

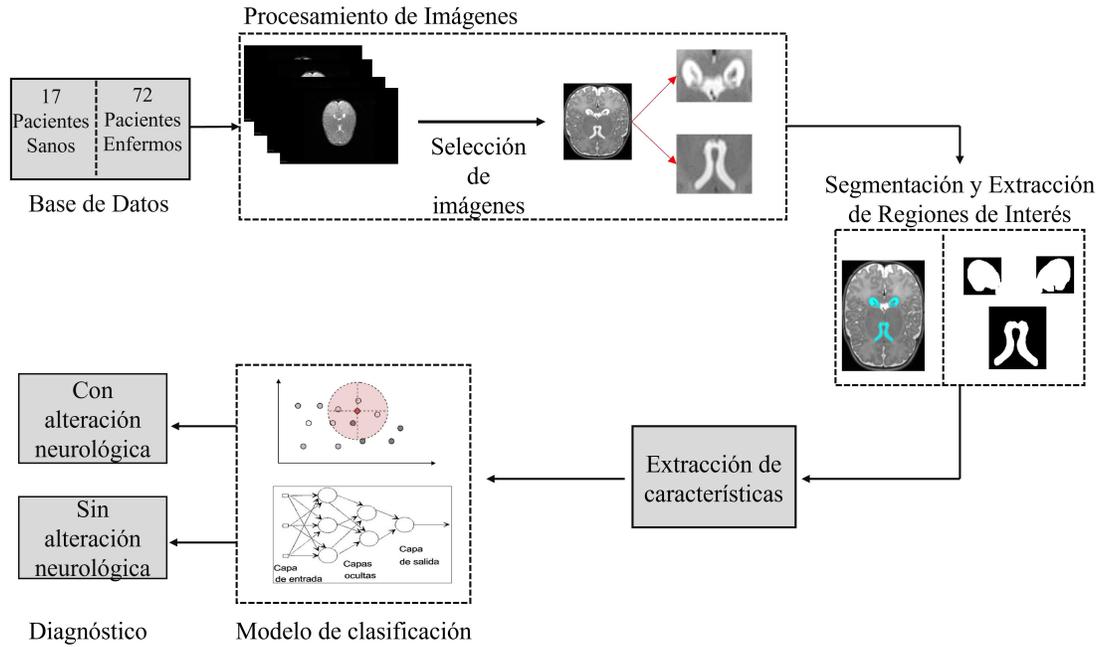


Figura 3.1: Planteamiento general del sistema.

3.1. Base de Datos

La base de datos fue obtenida en colaboración y consentimiento por la Unidad de Investigación en Neurodesarrollo (UIND) “Dr. Augusto Fernández Guardiola” y la Unidad de Resonancia Magnética del INB-UNAM Juriquilla, Querétaro, la cual, consta de imágenes de resonancia magnética de los pacientes adscritos al protocolo de “Lactantes con factores de riesgo para daño cerebral perinatal”.

Las imágenes adquiridas fueron analizadas por un resonador General Electric TM de 3T con una antena de 16 canales, las cuales presentan: Secuencias estructurales de resonancia magnética: imágenes ponderadas en T1, adquiridas con una secuencia 3D *fastfieldchoaxial*,

resolución de $1x1x1 \text{ mm}^3$, matriz de $224x224$, campo de visión de 22cm , 392 rebanadas oblicuas, tiempo de repetición (TR) $6,1\text{ms}$ y tiempo de eco (TE) 2.4 ms . Secuencias estructurales ponderadas en T2 con una secuencia *3D FastFieldEchoAxial*, resolución $1x1x1 \text{ mm}^3$, matriz de $224x224$, campo de visión 22cm , 196 rebanadas oblicuas, TR de 2500ms y TE de 68ms .

3.2. Selección de Imágenes de Resonancia Magnética

En colaboración con el especialista, se realizó la selección de imágenes de resonancia magnética de cada uno de los pacientes (figura 3.2). Mediante el software 3Dslicer se llevó a cabo la visualización de las imágenes a diferentes cortes (axial, coronal, sagital), eligiendo aquellas que mostraran los ventriculos laterales en un punto de interés aprobado por el especialista, eligiendo de estas imagenes las secuencias potenciadas en T2, debido a que este tipo de secuencias generan una hiperintensidad en aquellas zonas que cuentan con líquido cefalorraquídeo lo que permite ser aprovechado para los procesos de segmentación y extracción de características.

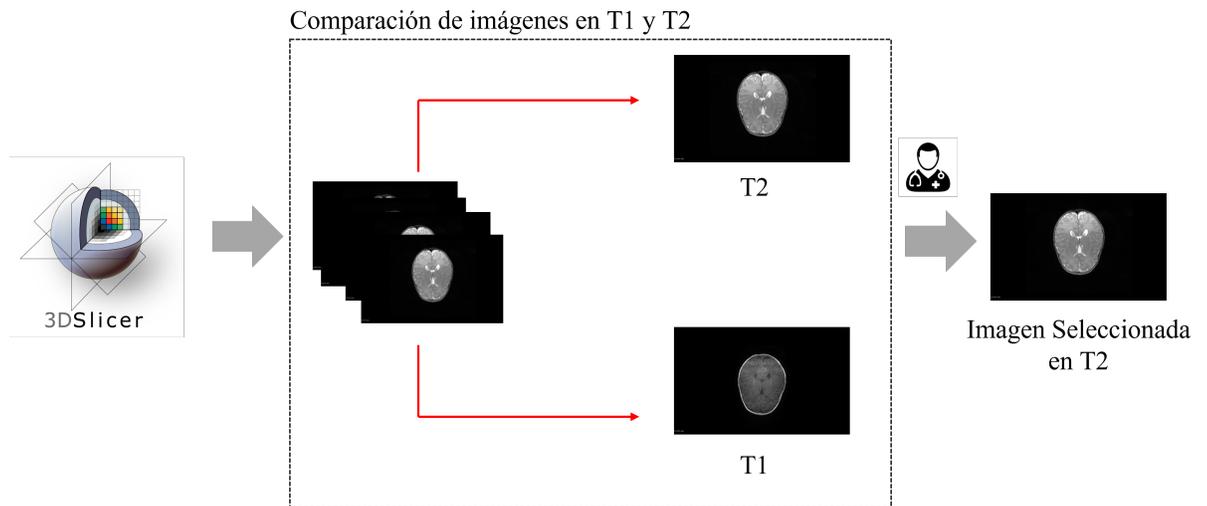


Figura 3.2: Selección de imágenes.

3.3. Preprocesamiento de Imágenes

Con el objetivo de acondicionar las imágenes seleccionadas, la etapa de preprocesamiento fue dividida en varias subetapas, eliminando en estas las diferentes regiones cuya presencia dificultaba los procesos posteriores. Como primer paso, las imágenes de entrada fueron filtradas mediante un filtro de suavizado gaussiano (Dahab *et al.*, 2012) definido mediante (1) utilizando una ventana deslizante de 5×5 . Al obtener las imágenes filtradas se creó un proceso para eliminar el fondo de cada una de las imágenes a partir de la búsqueda de píxeles que delimitaran la zona del cerebro, es decir, píxeles cuyo valor de intensidad fue superior a 0 (color negro) y a su vez píxeles ubicados al límite del área de interés, generando así una frontera que incluya únicamente la región de interés. Una vez delimitada la zona del cerebro, se recortó la imagen obteniendo únicamente los píxeles ubicados en el interior de la región delimitante (figura 3.3).

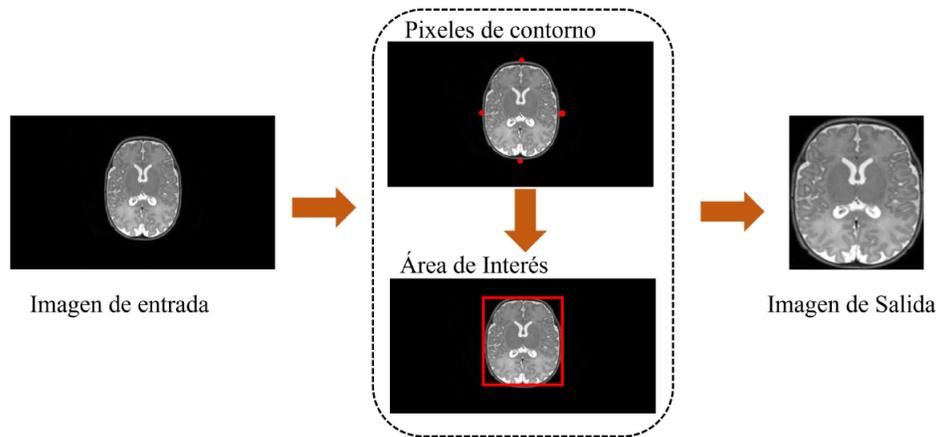


Figura 3.3: Preprocesamiento de imágenes: supresión de fondo

Al recortarse la imagen, esta se orientó en base a la posición promedio de las imágenes seleccionadas, es decir, cada una de las imágenes fue orientada de tal forma que el cuerpo posterior fuera posicionado en la zona superior de la imagen y el cuerpo anterior en la zona inferior, para esto, el proceso de orientación se basó en la estructura física del cerebro, ya que este posee una zona angosta y una zona ancha, basándose en esta estructura, se midió

la anchura en ambas zonas del cerebro (figura 3.4a), de esta forma, si la anchura de la zona superior era más pequeña que la anchura de la zona inferior entonces la imagen debe rotarse 180° (figura 3.4b).

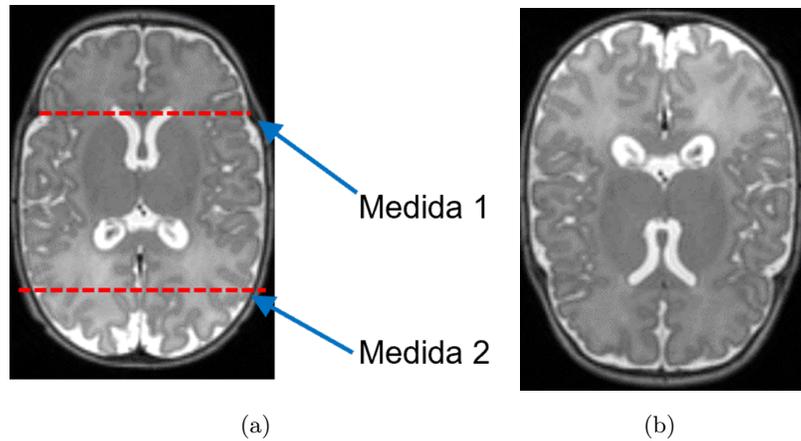


Figura 3.4: Preprocesamiento: a) Medición de anchura en zonas superior e inferior, b) Rotación de imágenes.

Al realizar la orientación de los ventrículos, se sustrajeron de forma separada las zonas de interés en base a la posición promedio de los ventrículos (figura 3.5a y 3.5b), esto con el fin de facilitar el proceso de segmentación, reduciendo la zona entorno de la región de interés y, por ende, la cantidad de información que puede perjudicar los siguientes procesos.

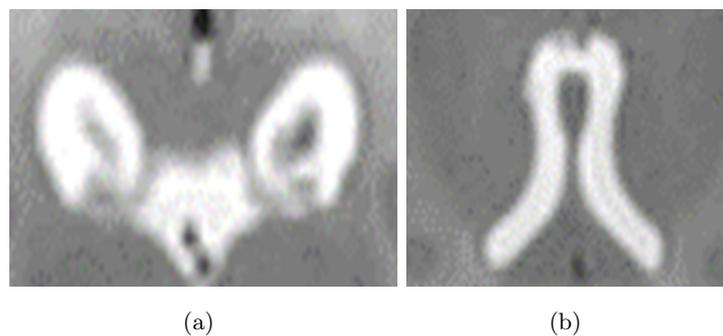


Figura 3.5: Preprocesamiento: a) Medición de anchura en zonas superior e inferior, b) Rotación de imágenes.

3.4. Procesamiento de Imágenes

Para llevar a cabo el proceso de segmentación de los ventrículos, se comenzó realizando un histograma de cada uno de los cuerpos (figura 3.6a y 3.6b), permitiendo así visualizar la variación en la intensidad entre las regiones de fondo y las regiones de interés y a su vez seleccionar los algoritmos con mayor probabilidad de segmentar las imágenes.

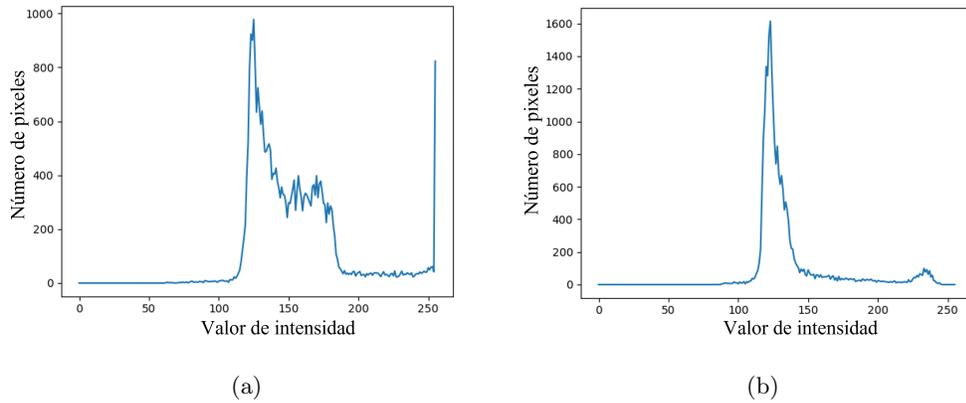


Figura 3.6: Obtención de histogramas, a) histograma del cuerpo posterior, b) histograma del cuerpo anterior.

Debido a la separación existente en la mayoría de los histogramas del cuerpo anterior, se eligió el algoritmo Otsu (Otsu, 1979), el cual, calcula el nivel de umbral basándose en la estructura de histogramas bimodales. El algoritmo Otsu permite obtener una representación binaria de la imagen de entrada siguiendo la ecuación definida en (2.2), tomando valores de 1 todas las regiones cuyos valores de intensidad sean superiores al umbral y 0 las regiones con valores inferior a este (figura 3.7a y 3.7b).



Figura 3.7: Cálculo automático del umbral: a) Representación del cuerpo posterior, b) Representación del cuerpo anterior.

Ya que el histograma del cuerpo posterior mostraba una distribución de intensidades más homogénea, el algoritmo Otsu resultó ser insuficiente para la segmentación del cuerpo posterior, por ello, las imágenes fueron segmentadas a partir de obtener la magnitud de los contornos de la imagen original mediante el algoritmo sobel (ecuación 2.9 y 2.10) como se muestra en la figura 3.8a. Debido a que el valor de la magnitud es mayor en las zonas correspondientes a la región de interés, se calculó un nivel de umbral T_m (ecuación 2) basado en el valor promedio de magnitudes, de esta forma se obtuvo una imagen binaria del contorno del cuerpo posterior (figura 3.8b).

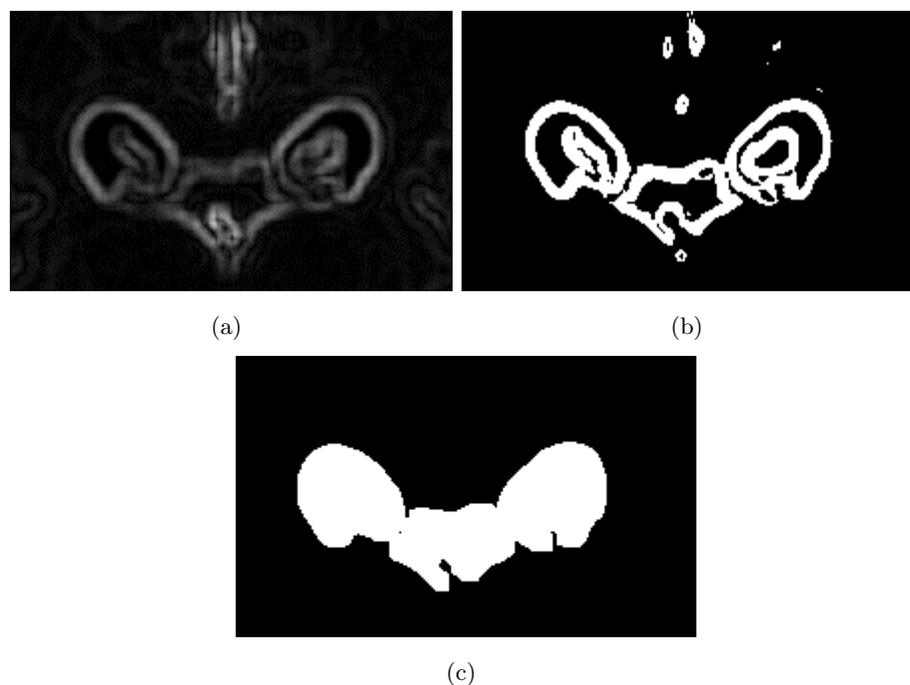


Figura 3.8: Algoritmo Sobel: a) Representación de la magnitud de los contornos en el cuerpo posterior, b) Representación del contorno adquirido, c) Cuerpo posterior resultante.

Por último, se obtuvo la imagen binaria mostrada en la figura 3.8c rellenando los huecos a partir de utilizar el contorno obtenido como frontera y eliminando el ruido espurio mediante una apertura morfológica (Zhang *et al.*, 2019).

Una vez obtenida la imagen limpia, se llevó a cabo el proceso de segmentación de ventrículos, los cuales, debido a su estructura, poseen una ubicación característica dentro de la imagen (figura 3.9).



Figura 3.9: Delimitación de ventrículos.

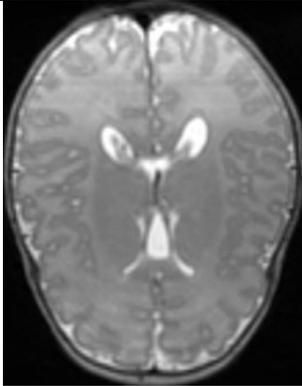
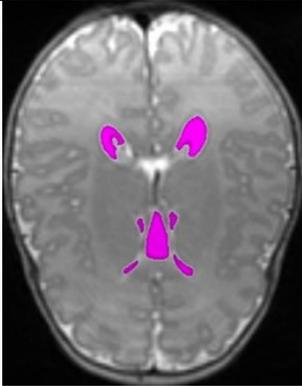
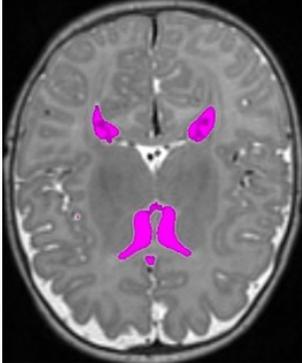
Basándose en dicha ubicación, se realizó de forma automática la delimitación circular de los ventrículos posteriores a partir de obtener una aproximación del centro y el radio de cada uno de ellos. Para obtener una aproximación del centro de cada ventrículo, se llevó a cabo un proceso de erosión iterativa utilizando (12), esto con el fin de eliminar todas las regiones hasta llegar a un punto central de los ventrículos. Una vez obtenida la aproximación del punto central de imagen original, se buscó el píxel cuya ubicación dentro de la imagen tuviera el valor mínimo, es decir, la ubicación más alejada del punto central. Una vez obtenidos la posición central del ventrículo y el radio hacia el punto más alejado de este, se generó una circunferencia que permitiera delimitar la zona (figura 3.10a) y, por ende, extraer los ventrículos del cuerpo posterior (figura 3.10b)

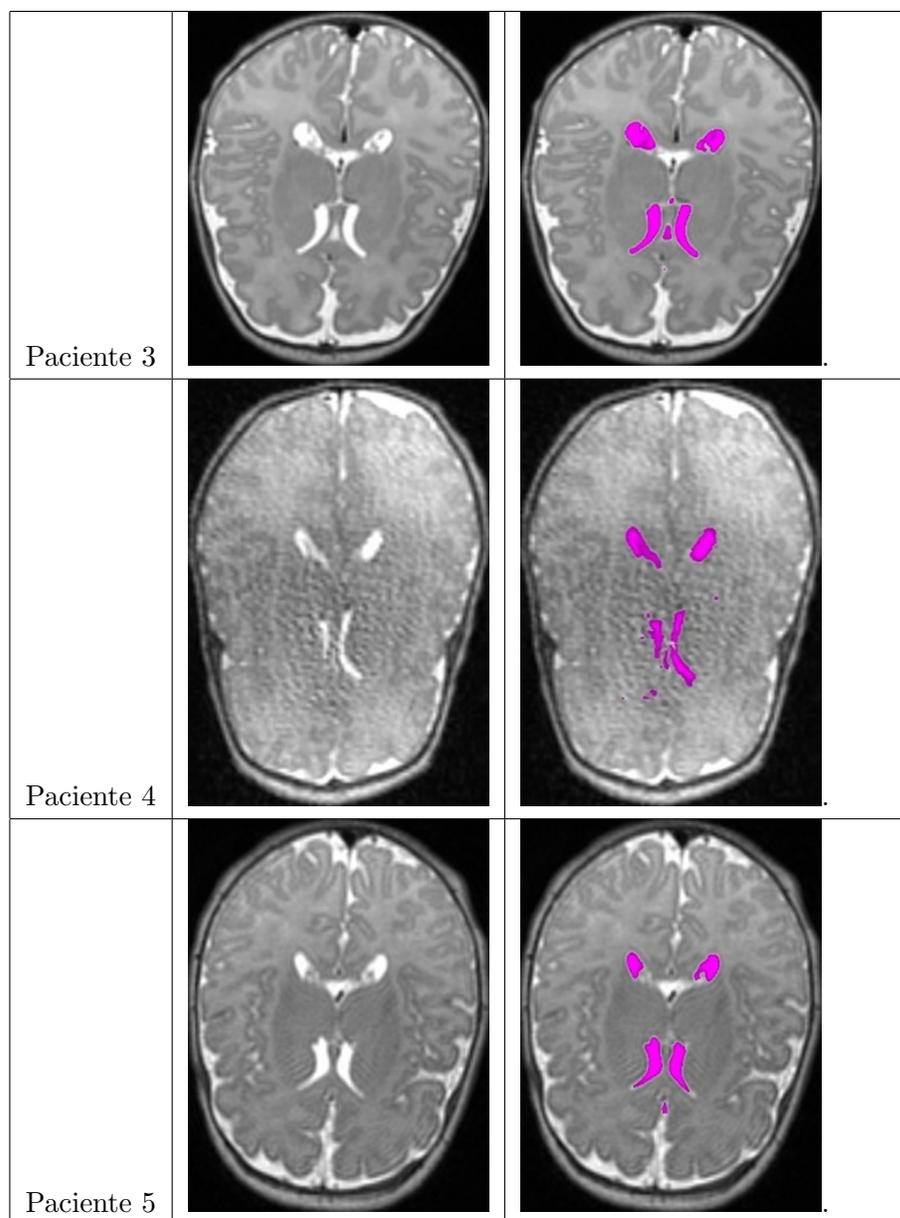


Figura 3.10: a) Delimitación mediante la posición central y el radio de los ventrículos, b) Región obtenida.

3.5. Segmentación de Imágenes

Con la finalidad de realizar el proceso de segmentación, se utilizaron las máscaras de las regiones de interés obtenidas en el apartado anterior, siendo la figura 3.7b la máscara utilizada para segmentar el cuerpo anterior y la figura 3.10b la máscara del cuerpo posterior, de esta forma se sobrescribió sobre cada una de las imágenes originales las regiones ventriculares, permitiéndole al especialista contar con panorama general de las IMR así como de los ventrículos laterales segmentados, en la tabla 3.1 se muestran 6 de las 89 imágenes obtenidas.

	Imagen Original	Imagen Segmentada
Paciente 1		
Paciente 2		



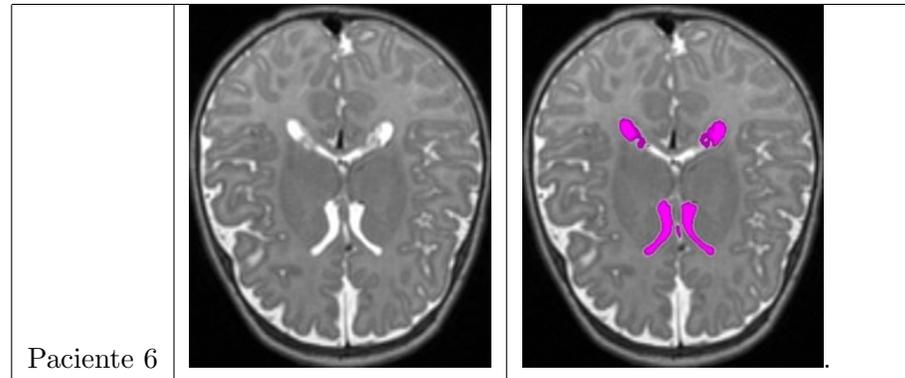


Tabla 3.1: Comparación de imágenes originales con respecto a las imágenes segmentadas.

3.6. Extracción De Características

Debido a que la precisión del modelo de segmentación era aproximadamente 85% (76 imágenes), se buscó obtener las regiones de interés de las demás imágenes a partir de conocer posición de los ventrículos correctamente segmentados, se llevó a cabo la búsqueda de las imágenes mal segmentadas y se fijaron los límites entre cada ventrículo a partir de la posición promedio de aquellos correctamente segmentados; así, al obtener las ubicaciones aproximadas de los cuerpos, se extrajeron las regiones de interés de cada una de las resonancias magnéticas (Ventrículos posteriores y anteriores). Una vez obtenidas, se llevó a cabo la elección de las imágenes en escala de grises y binaria (figuras 3.10) con el fin de obtener una mayor variedad de características que permitan la identificación de alteraciones.

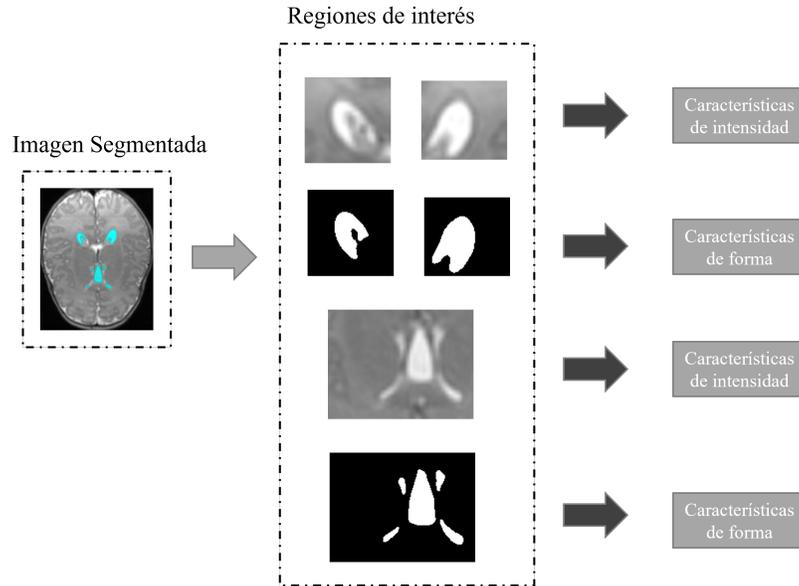


Figura 3.11: Selección de imágenes para extracción de características.

3.6.1. Matriz de Características.

Gracias a las diferentes representaciones de las regiones de interés se obtuvieron 32 características por paciente, de las cuales destacan aquellas que consideran la forma de los ventrículos, tales como, el área (17), el perímetro (18), centro de masa (22), Hu momentos de la imagen (25-31): h_i con $i = 1, \dots, 7$, redondez (19) y extensión ventricular (32). Así mismo, adicionales a estas, se obtuvieron características cuyos valores están asociados a las diferentes intensidades presentes en los píxeles de los ventrículos, características como el valor medio de gris (33) y el nivel de contraste (34). Cada una de las características fue almacenada en una tabla de tal forma que las filas indiquen el número del paciente y las columnas el número total de características como se muestra en el diagrama de la figura 3.11.

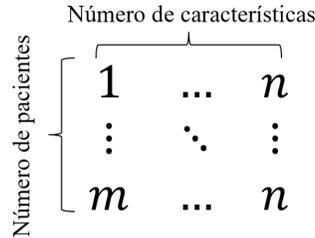


Figura 3.12: Representación de matriz de características, donde m es el número total de pacientes y n el número total de características.

3.6.2. Normalización De Datos.

Ya que entre la mayoría de las características existe una desigualdad entre sus rangos a causa de las propiedades de las características, es necesario normalizar cada una de las columnas con el fin de evitar que aquellas cuyos valores cuentan con un rango mayor influyan en mayor proporción el modelo de clasificación a diferencia de aquellas con un rango muchísimo menor. Para ello, existe una variedad de métodos que permiten normalizar la información en diferentes rangos, sin embargo, para el conjunto de características se utilizó la normalización definida como la normalización Min-Max [8], la cual, permite trasladar cada uno de los rangos de la matriz de características a un único rango de valores de $[0,1]$.

3.7. Diagnóstico Del Especialista (Clasificación De Los Pacientes)

Para llevar a cabo el entrenamiento del modelo inteligente, se necesitó, por parte de un especialista, llevar a cabo el diagnóstico de cada una de las imágenes segmentadas, dentro de dicho diagnóstico se menciona cuáles de los pacientes poseen de forma aparente alguna enfermedad neurológica, así como una descripción breve del diagnóstico, cuya valoración está enfocada únicamente a anomalías relacionadas con los ventrículos laterales, siendo ventrículos laterales aumentados, leucomalacia paraventricular y espacio subaracnoideo aumentado algunas de las anomalías que más destacan. Realizando una clasificación, el especialista

separó al número total de pacientes (89 pacientes) por clases, siendo de la clase 0 todos aquellos pacientes cuyo diagnóstico fue el de “aparentemente normal” y de la clase 1 todos aquellos pacientes cuyo diagnóstico fue “patológico” (tabla 3.2), obteniendo como resultado un total de 17 pacientes diagnosticados como “aparentemente normal” (clase 0) y 72 pacientes diagnosticados como “patológico” (clase 1).

No. de paciente	Clasificación	Diagnóstico
1	0	
2	1	Ventrículos laterales aumentados
3	1	Leucomalacia paraventricular (LPV)
4	0	
5	1	Ventrículos laterales aumentados, posible LPV

Tabla 3.2: Clasificación de los pacientes por el especialista.

3.8. Modelo de Clasificación

A causa del número total de pacientes y al número total de clases, se decidió implementar 3 diferentes modelos con la finalidad de comparar el porcentaje de efectividad al momento de clasificar los datos. Cada uno de los modelos seguirá la misma metodología de distribución de los datos y evaluación de las clases definidas en el diagrama de la figura 3.12. Donde el conjunto de datos será separado en dos subconjuntos, un conjunto con el 80% de los datos para entrenar el clasificador (es decir, aproximadamente 71 pacientes) y un conjunto con el 20% restante (18 pacientes) para evaluar el modelo.

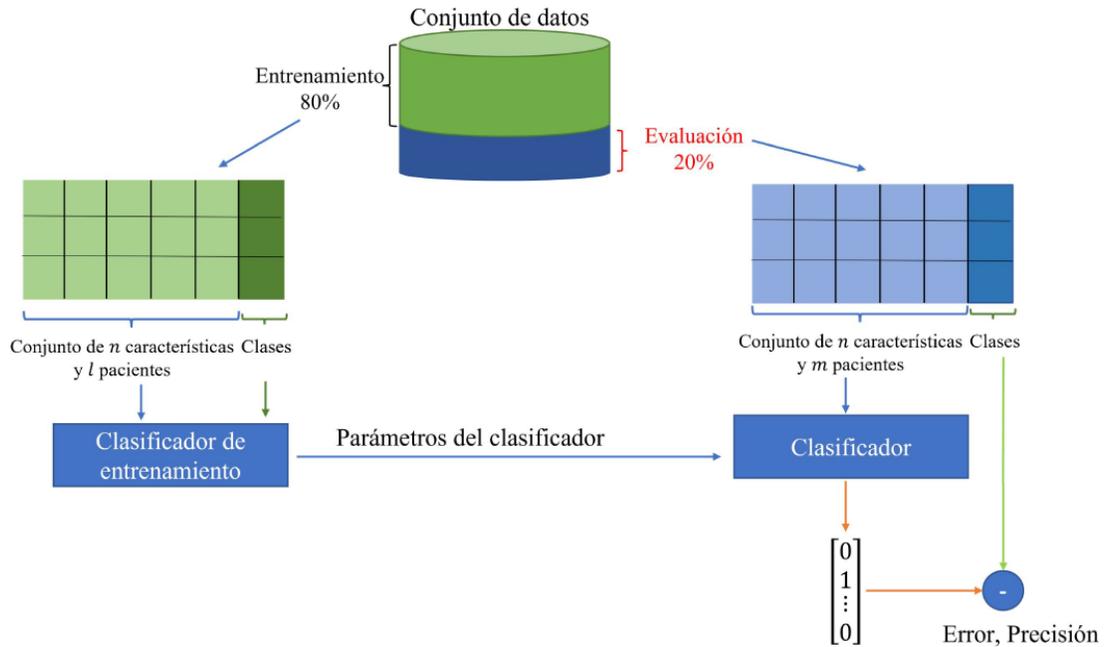


Figura 3.13: Metodología de distribución de datos y evaluación del modelo inteligente.

3.8.1. Regresión Logística.

La regresión logística múltiple (definida mediante la ecuación 16) fue utilizada como modelo de clasificación, ya que, resulta ser una herramienta eficaz cuando se tienen variables dependientes dicotómicas (cuya ausencia o presencia se ha puntuado con los valores cero y uno, respectivamente) y a su vez un conjunto de variables predictoras similares al conjunto de datos y al número de clases de este estudio. Para el diseño de la regresión logística se definieron los parámetros mostrados en la tabla 3.3, utilizando como entradas al número total de características y como muestras de entrenamiento el 80% del número total de pacientes.

Características del modelo	Valores
Muestras de entrenamiento (80%)	71
Número de entradas	32
Máximo de iteraciones	20000
Solucionador	Lbfgs
Factor de penalización	1e5

Tabla 3.3: Características del modelo de Regresión logística

3.8.2. Redes neuronales artificiales.

Del mismo modo que el modelo de regresión logística, se definió la estructura de una red neuronal artificial, debido a su utilidad en el proceso de clasificación de patrones. Sin embargo, debido a que el modelo de una red neuronal requiere de un número relativamente alto de muestras, se implementó un sobremuestreo de clases por duplicación aleatoria, reutilizando los datos de entrenamiento y la experiencia obtenida para mejorar el aprendizaje del modelo (Wibowo & Fatichah, 2021; Barua *et al.*, 2012, Jo & Japkwicz, 2004, Mease *et al.*, 2007)

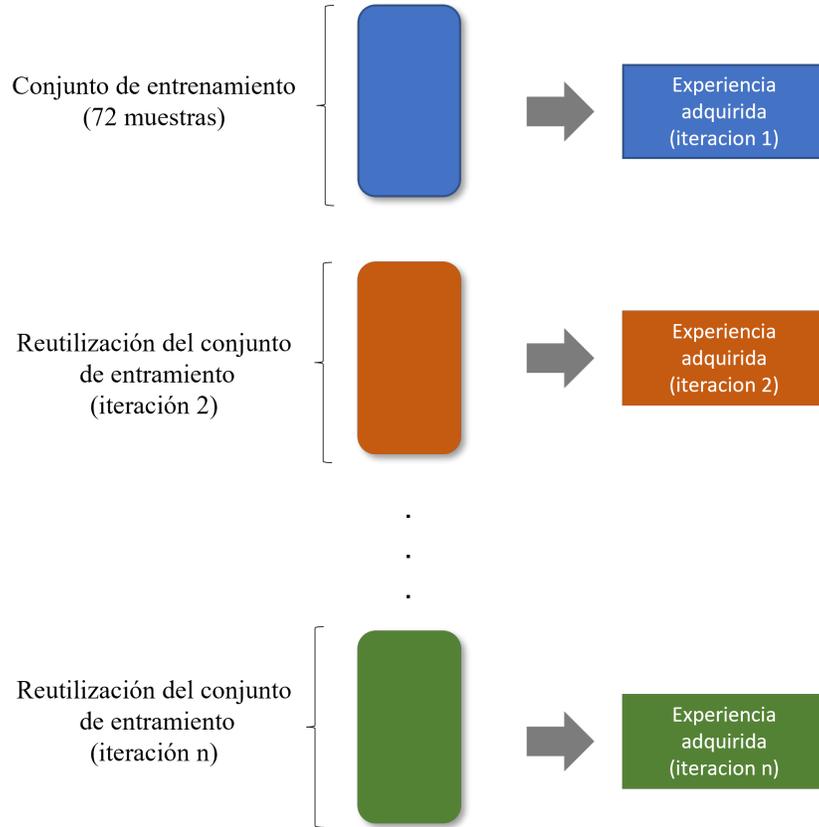


Figura 3.14: Proceso de entrenamiento de la red neuronal.

Para la topología de la red neuronal se definieron los parámetros mostrados en la tabla 3.4, utilizando como entradas el número total de características y muestras 13 iteraciones del 80% del número total de pacientes.

Características del modelo	Valores
Muestras de entrenamiento (80%)	926
Número de entradas	32
Máximo de iteraciones	200
Nodos de la capa oculta	[5,3]
Coefficiente de aprendizaje	1e-3
Solucionador	Lbfgs
Función de activación	Logistic, tanh

Tabla 3.4: Características del modelo de Red Neuronal

3.8.3. K-vecinos cercanos (K- nearest neighbor)

El algoritmo k - *nearestNeighbor* (*KNN*) (Rodríguez-Vázquez *et al.*, 2016) permitió para este estudio llevar a cabo la clasificación de los datos buscando la probabilidad de que un paciente x pertenezca a la clase C_j a partir de los k valores más cercanos. El modelo de *KNN* para la clasificación de los pacientes fue desarrollado utilizando valores de $k = 5$ con el fin de observar la efectividad del algoritmo ante diferentes valores de k .

Capítulo 4

Resultados

Llevando a cabo la implementación de cada uno de los modelos de clasificación a partir de las características mostradas en las tablas 3.3 y 3.4, se pudo obtener la matriz de confusión de cada uno de los sistemas.

4.1. Matriz de confusión de la regresión logística

A causa de la poca cantidad de muestras de la clase “sano” (17 muestras) y a la elevada disparidad de muestras que existe entre ambas clases, el modelo de la regresión logística no pudo encontrar los parámetros que le permitieran al conjunto de evaluación elevar la precisión por encima del 70% (tabla 4.1).

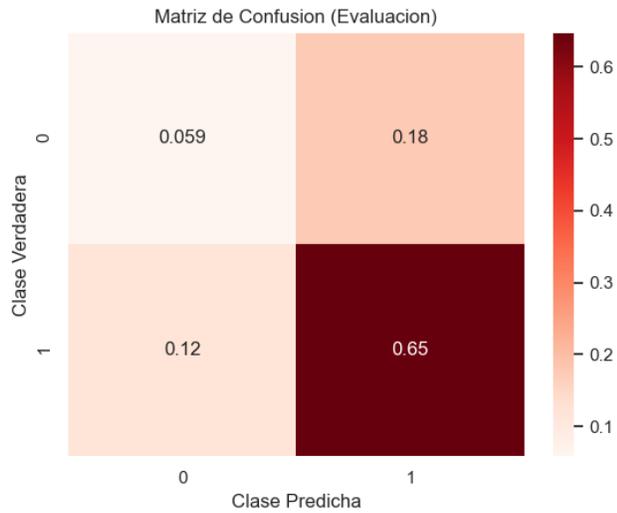
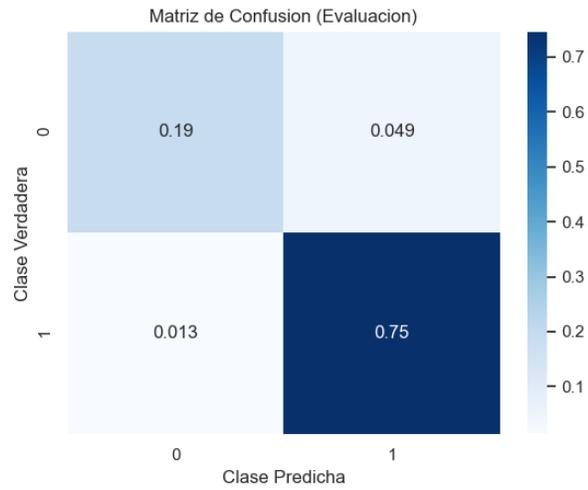


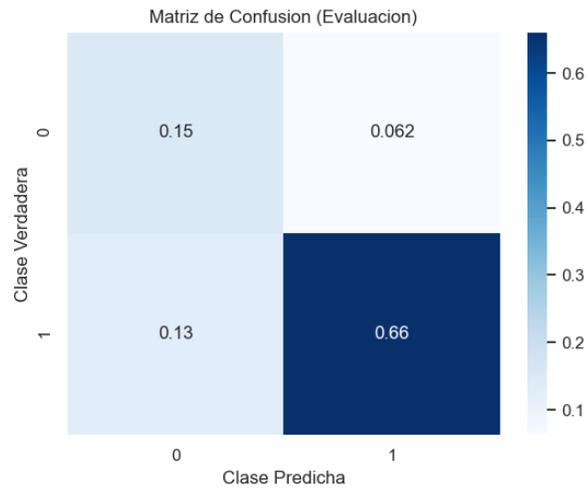
Figura 4.1: Matriz de confusión del conjunto de evaluación.

4.2. Matriz de confusión de la red neuronal artificial

Utilizando las funciones de activación “Logistic” y “tanh” y a su vez utilizando el proceso de aprendizaje iterativo pudo llevarse a cabo la clasificación de los pacientes evitando el problema de la disparidad entre clases, obteniéndose un porcentaje de precisión aceptable en el conjunto de evaluación (como se muestra en la tabla 4.1), colocándose como una mejor herramienta la función de activación “Logistic” para la clasificación de pacientes por redes neuronales artificiales



(a)



(b)

Figura 4.2:) Matriz de confusión del conjunto de evaluación utilizando una función de activación “logistic”, b) Matriz de confusión del conjunto de evaluación utilizando una función de activación “tanh”..

4.3. K-vecinos cercanos (K- nearest neighbor)

Basándose en los resultados obtenidos, el algoritmo de KNN resulto ser ineficiente debido a la disparidad que existe entre las clases, ya que, al ser la clase 0 (pacientes sanos) demasiado pequeña, el modelo de entrenamiento elige clasificar todos los elementos como la clase predominante.

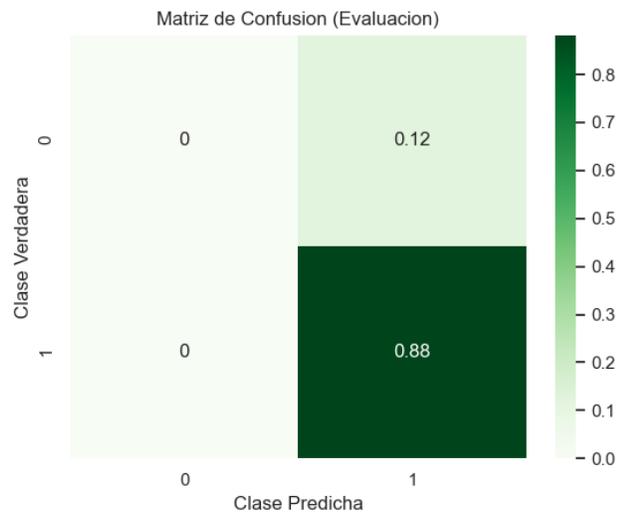


Figura 4.3: Matriz de confusión del conjunto de evaluación.

Una vez obtenidas las matrices de confusión de cada modelo, se llevó a cabo el cálculo de los indicadores de evaluación con el fin de comparar la eficacia de los modelos (tabla 4.1).

	Precisión (AC)	Error (E)
Regresión logística	70.9 %	29.1 %
Red neuronal (logistic)	93.81 %	6.19 %
Red neuronal (tanh)	80.83 %	19.71 %
KNN	88 % (Ajuste a la clase predominante)	12 %

Tabla 4.1: Indicadores de evaluación

Por último, se llevó a cabo la integración de cada una de las etapas con el fin de calcular el tiempo aproximado de ejecución, considerando las etapas de segmentación, extracción de características e implementación de los diferentes modelos inteligentes (tabla 4.2), obteniendo como resultado un tiempo aproximado de 10 minutos, siendo el proceso de extracción de características el proceso con mayor consumo de tiempo.

	Segmen tación	Extracción de características	Modelo inteligente		
			Regresión Logística	KNN	Red Neuronal
Tiempo(seg)	4.7908	582.482	0.641	0.544	0.714

Tabla 4.2: Tiempo de ejecución

Capítulo 5

Conclusiones

Finalmente, se hizo una recopilación de las conclusiones obtenidas a lo largo de los capítulos anteriores. Así mismo, se destacan los objetivos conseguidos, así como las posibles mejoras de este trabajo de tesis.

5.1. Conclusiones generales

Se desarrolló una técnica de segmentación automática de ventrículos laterales basada en umbralización OTSU, detección de contornos y operadores morfológicos, permitiendo así, extraer indicadores cuantitativos basados en la forma e intensidad de las regiones de interés. Se implementó un sistema inteligente basado en el procesamiento de imágenes de resonancia magnética utilizando diferentes modelos de aprendizaje automático.

Se llevó a cabo la clasificación de las imágenes de resonancia magnética realizando una comparación entre los modelos de aprendizaje, regresión logística, K-vecinos cercanos y redes neuronales obteniendo como resultado a las redes neuronales como el mejor modelo para clasificar a los pacientes, alcanzando una precisión superior al 90% y un tiempo aproximado de 10 minutos en la ejecución del sistema.

Debido al limitado número de pacientes sanos así como al número de pacientes en gene-

ral, los modelos inteligentes de regresión logística y K-vecinos cercanos no pudieron clasificar de una forma más eficiente la presencia de alteraciones neurológicas, sin embargo, fue posible a partir de diferentes métodos de entrenamiento alcanzar una precisión aceptable superior al 70% mediante métodos de regresión logística y superior al 85% mediante modelos de redes neuronales artificiales.

Capítulo 6

Prospectivas

Mejorar la precisión de los modelos inteligentes a partir de utilizar una mayor cantidad de imágenes de resonancia magnética.

Implementar técnicas de extracción de características de IRM y modelos inteligentes en arquitecturas digitales con el fin de desarrollar dispositivos de asistencia médica.

Bibliografía

- [1] Aguirre, J. A., Donato, M. L., Buscio, M., Ceballos, V., Armeno, M., Aizpurúa, L., & Arpi, L. (2019). Compromiso neurológico grave por déficit de vitamina B12 en lactantes hijos de madres veganas y vegetarianas. *Arch Argent Pediatr*, 117(4), e420-4.
- [2] Berón Rivera, J. D. (2020). Clasificación de enfermedades en la caja torácica por medio de radiografías.
- [3] Barua, S., Islam, M. M., Yao, X., & Murase, K. (2012). MWMOTE-majority weighted minority oversampling technique for imbalanced data set learning. *IIE Transactions on knowledge and data engineering*, 26(2), 405-425.
- [4] Buzai, G. D., & Galbán, E. M. (2020). Megaciudad Buenos Aires: Cartografía de su última expansión y conurbación mediante el procesamiento digital de imágenes satelitales nocturnas. *Revista Cartográfica*, (100), 215-238.
- [5] Campos Montero, Z. I. (2009). Problemas de la alimentación en lactantes. Primera parte: generalidades. *Acta Pediátrica Costarricense*, 21(1), 18-25.
- [6] Casey, S. O., Sampaio, R. C., Michel, E., & Truwit, C. L. (2000). Posterior reversible encephalopathy syndrome: utility of fluid-attenuated inversion recovery MR imaging in the detection of cortical and subcortical lesions. *American Journal of Neuroradiology*, 21(7), 1199-1206.
- [7] Charfi, S., Lahmyed, R., & Rangarajan, L. (2014). A novel approach for brain tumor detection using neural network. *International Journal of Research in Engineering and Technology*, 2(7), 93-104.
- [8] Chitarroni, H. (2002). La regresión logística.

BIBLIOGRAFÍA

- [9] Chowdhury, D. R., Chatterjee, M., & Samanta, R. K. (2011). An artificial neural network model for neonatal disease diagnosis. *International Journal of Artificial Intelligence and Expert Systems (IJAE)*, 2(3), 96-106.
- [10] Clark, C. A., & Woodward, L.J. (2010). Neonatal cerebral abnormalities and later verbal and visuospatial working memory abilities of children born very preterm. *Developmental neuropsychology*, 35(6), 622-642.
- [11] Cruz-Albarran, I. A., Benitez-Rangel, J. P., Osornio-Rios, R. A., & Morales-Hernandez, L. A. (2017). Human emotions detection based on a smart-thermal system of thermographic images. *Infrared Physics & Technology*, 81, 250-261.
- [12] Dahab, D. A., Ghoniemy, S. S., & Selim, G. M. (2012). Automated brain tumor detection and identification using image processing and probabilistic neural network techniques. *International journal of image processing and visual communication*, 1(2), 1-8.
- [13] Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of biomedical informatics*, 35(5-6), 352-359.
- [14] Fraello, D., Maller-Kesselman, J., Vohr, B., Katz, K. H., Kesler, S., Schneider, K., ... & Spann, M. N. (2011). Consequence of preterm birth in early adolescence: the role of language on auditory short-term memory. *Journal of child neurology*, 26(6), 738-742.
- [15] Garduño-Ramón, M. A., Sánchez-Gómez, J. I., Morales Hernández, L. A., Benítez-Rangel, J. P., & Osornio-Rios, R. A. (2014). Methodology for automatic detection of trees and shrubs in aerial pictures from UAS.
- [16] Grosse, C., & Simeoni, U. (2012). Enfermedades neurológicas relacionadas con la prematuridad. *EMC-Pediatría*, 47(4), 1-7.
- [17] Heinze, G., Canchola, V. H. O., Miranda, G. B., Fuentes, N. A. B., & Sánchez, D. P. G. (2018). Los médicos especialistas en México. *Gaceta médica de México*, 154(3), 342-351.
- [18] Hinojosa-Rodríguez, M., De Leo-Jiménez, J. O., Juárez-Colín, M. E., Gonzalez-Moreira, E., Flores-Bautista, C. S., & Harmony, T. (2020). Long-term therapeutic effects of Katona therapy in moderate-to-severe perinatal brain damage. *Neuroscience Letters*, 738, 135345.

BIBLIOGRAFÍA

- [19] Inder, T. E., Wells, S. J., Mogridge, N. B., Spencer, C., & Volpe, J. J. (2003). Defining the nature of the cerebral abnormalities in the premature infant: a qualitative magnetic resonance imaging study. *The Journal of pediatrics*, 143(2), 171-179.
- [20] Isoglu, S., Koca, E. I., & Duru, D. G. (2017, April). Comparative multiple sclerosis lesion segmentation in magnetic resonance images. In *2017 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)* (pp. 1-4). IEEE.
- [21] Jeyavathana, R. B., Balasubramanian, R., & Pandian, A. A. (2016). A survey: analysis on pre-processing and segmentation techniques for medical images. *International Journal of Research and Scientific Innovation (IJRSI)*.
- [22] Jo, T., & Japkowicz, N. (2004). Class imbalances versus small disjuncts. *ACM Sigkdd Explorations Newsletter*, 6(1), 40-49.
- [23] Klette, R. (2014). *Concise computer vision*. Springer, London.
- [24] Lamy, C., Oppenheim, C., Meder, J. F., & Mas, J. L. (2004). Neuroimaging in posterior reversible encephalopathy syndrome. *Journal of Neuroimaging*, 14(2), 89-96.
- [25] Laureta, E., Mizrahi, E. M., & Moshé, S. L. (2012). Seizures and epilepsies in the preterm and term neonate. In *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields: Sixth Edition* (pp. 465-478). Wolters Kluwer Health Adis (ESP).
- [26] Letteboer, M., Niessen, W., Willems, P., Dam, E. B., & Viergever, M. (2001). Interactive multi-scale watershed segmentation of tumors in MR brain images. In *Proc. of the IMIVA workshop of MICCAI*.
- [27] Li, D. (2010). Analysis of moment invariants on image scaling and rotation. In *Innovations in Computing Sciences and Software Engineering* (pp. 415-419). Springer, Dordrecht.
- [28] López-Azorín, M., Ybarra, M., & Cabañas, F. (2012). *Ecografía cerebral en neonatos*. *Anales de Pediatría Continuada*, 10(4), 228-233.
- [29] Llaugel, F. A., & Fernández, A. I. (2011). Evaluación del uso de modelos de regresión logística para el diagnóstico de instituciones financieras. *Ciencia y sociedad*.

BIBLIOGRAFÍA

- [30] Mahmoud, A. S., Mostafa, M. K., & Nasr, M. (2019). Regression model, artificial intelligence, and cost estimation for phosphate adsorption using encapsulated nanoscale zero-valent iron. *Separation Science and Technology*, 54(1), 13-26.
- [31] Martinez-Biarge, M., Groenendaal, F., Kersbergen, K. J., Benders, M. J., Foti, F., Cowan, F. M., & de Vries, L. S. (2016). MRI based preterm white matter injury classification: the importance of sequential imaging in determining severity of injury. *PLoS One*, 11(6), e0156245.
- [32] Mathur, A., & Inder, T. (2009). Magnetic resonance imaging—insights into brain injury and outcomes in premature infants. *Journal of communication disorders*, 42(4), 248-255.
- [33] Mease, D., Wyner, A.J., & Buja, A. (2007). Boosted Classification Trees and Class Probability/ Quantile Estimation. *J. Machine Learning Research*, vol.8, 409-439.
- [34] Mery, D. (2015). Computer vision for X-Ray testing. *Switzerland: Springer International Publishing*, 10, 978-3
- [35] Mizrahi, E. M., & Kellaway, P. (1987). Characterization and classification of neonatal seizures. *Neurology*, 37(12), 1837-1837.
- [36] Moreno-Flagge, N. (2013). Trastornos del lenguaje. Diagnóstico y tratamiento. *Rev Neurol*, 57(Supl 1), S85-94.
- [37] Moore, T., Hennessy, E. M., Myles, J., Johnson, S. J., Draper, E. S., Costeloe, K. L., & Marlow, N. (2012). Neurological and developmental outcome in extremely preterm children born in England in 1995 and 2006: the EPICure studies. *Bmj*, 345.
- [38] Ng, H. P., Ong, S. H., Foong, K. W. C., Goh, P. S., & Nowinski, W. L. (2006, March). Medical image segmentation using k-means clustering and improved watershed algorithm. In *2006 IEEE southwest symposium on image analysis and interpretation* (pp. 61-65). IEEE.
- [39] Oishi, K., Mori, S., Donohue, P. K., Ernst, T., Anderson, L., Buchthal, S., ... & Chang, L. (2011). Multi-contrast human neonatal brain atlas: application to normal neonate development analysis. *Neuroimage*, 56(1), 8-20.
- [40] Ortiz, O. J. R., Mejia, M., & Useche-Castelblanco, J. S. (2019). Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos. *Revista EIA*, 16(31), 189-207.

- [41] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66
- [42] Parikh, N. A. (2016, December). Advanced neuroimaging and its role in predicting neurodevelopmental outcomes in very preterm infants. In *Seminars in perinatology* (Vol. 40, No. 8, pp. 530-541). WB Saunders
- [43] Peterson, B. S., Anderson, A. W., Ehrenkranz, R., Staib, L. H., Tageldin, M., Colson, E., . . . & Ment, L. R. (2003). Regional Brain volumes and their later neurodevelopmental correlates in term and preterm infants. *Pediatrics*, 111(5), 939-948.
- [44] Pisani, F., Spagnoli, C., Pavlidis, E., Facini, C., Ntonfo, G. M. K., Ferrari, G., & Raheli, R. (2014). Real-time automated detection of clonic seizures in newborns. *Clinical neurophysiology*, 125(8), 1533-1540.
- [45] Ramírez Pérez, N. A. (2020). Modelo de clasificación automática de imágenes de resonancia magnética para el diagnóstico del cáncer de próstata.
- [46] Rebolledo, F. A. (2004). El diagnóstico por imagen en el niño con problemas neuropsicológicos. *Plasticidad y Restauración Neurológica*, 3(1-2), 63-72.
- [47] Romero Guzmán, G. J. (2019). *Detección de lesiones isquémicas y hemorrágicas en recién nacidos prematuros con ecografía de alta resolución* (Doctoral dissertation).
- [48] Sahoo, P.K., Soltani, S., Wong, A.K., Chan, Y.C. (1988). A survey of thresholding techniques. *Computer Vision, Graphics and Image Processing* 41, 233-260.
- [49] Sánchez, N., Castoldi, M. F., & Stecher, X. (2014). RM de encéfalo sin anestesia en pacientes recién nacidos: Experiencia inicial en Clínica Alemana de Santiago. *Revista chilena de radiología*, 20(4), 143-148.
- [50] Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., ... & Ortiz, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista argentina de radiología*, 79(4), 192-204.
- [51] Savasci, D., Ornek, A. H., Ervural, S., Ceylan, M., Konak, M., & Soyulu, H. (2019). Classification of unhealthy and healthy neonates in neonatal intensive care units using medical thermography processing and artificial neural network. In *Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis* (pp. 1-29). Academic Press.

BIBLIOGRAFÍA

- [52] Senthilkumaran, N., & Vaithegi, S. (2016). Image segmentation by using thresholding techniques for medical images. *Computer Science & Engineering: An International Journal*, 6(1), 1-13.
- [53] Shenbagarajan, A., Ramalingam, V., Balasubramanian, C., & Palanivel, S. (2016). Tumor diagnosis in MRI brain image using ACM segmentation and ANN-LM classification techniques. *Indian Journal of Science and Technology*, 9(1), 1-12.
- [54] Somasundaram, K., & Genish, T. (2012, December). Segmentation of hippocampus from human brain MRI using mathematical morphology and fuzzy logic. In *2012 International Conference on Emerging Trends in Science, Engineering and Technology (INCOSSET)* (pp. 269-273). IEEE.
- [55] Steger, S., & Sakas, G. (2011, September). FIST: fast interactive segmentation of tumors. In *International MICCAI Workshop on Computational and Clinical Challenges in Abdominal Imaging* (pp. 125-132). Springer, Berlin, Heidelberg.
- [56] Taylor, H. G., Klein, N., Minich, N. M. & Hack, M. (2000). Middle-school-age outcomes in children with very low birthweight. *Child development*, 71(6). 1495-1511.
- [57] Vericat, A., & Orden, A. B. (2017). Riesgo neurológico en el niño de mediano riesgo neonatal. *Acta pediátrica de México*, 38(4), 255-266.
- [58] Vincent, O. R., & Folorunso, O. (2009, June). A descriptive algorithm for sobel image edge detection. In *Proceedings of informing science & IT education conference (InSITE)* (Vol. 40, pp. 97-107)
- [59] Wibowo, P. & Fatichah, C. (2021). An in-depth performance analysis of the oversampling techniques for high-class imbalanced dataset. *Register: Jurnal Ilmiah Teknologi Sistem Informatika*, 7(1), pp.63-71.
- [60] Xu, J., Zhang, Y., & Miao, D. (2020). Three-way confusion matrix for classification: A measure driven view. *Information sciences*, 507, 772-794.
- [61] Yang, H., Zhang, J., Liu, Q., & Wang, Y. (2018). Multimodal MRI-based classification of migraine: using deep learning convolutional neural network. *Biomedical engineering online*, 17(1), 1-14.

BIBLIOGRAFÍA

- [62] Zhang, C., Shen, X., Cheng, H., & Qian, Q. (2019). Brain tumor segmentation based on hybrid clustering and morphological operations. *International journal of biomedical imaging*, 2019.
- [63] Zhang, W., Li, R., Deng, H., Wang, L., Lin, W., Ji, S., & Shen, D. (2015). Deep convolutional neural networks for multi-modality isointense infant brain image segmentation. *NeuroImage*, 108, 214-224.

Anexos

Anexo I: Carta de autorización para el uso de la base de datos.



A QUIEN CORRESPONDA:
Presente.

Por este conducto me permito informales que se autoriza la utilización y análisis de datos procedentes del protocolo “Desarrollo de métodos para el diagnóstico y tratamiento temprano de recién nacidos con factores de riesgo prenatales y perinatales”, bajo la dirección de la Dra. Thalía Harmony Baillet, directora de la Unidad de Investigación en Neurodesarrollo (UIND) “Dr. Augusto Fernández Guardiola” al **Lic. En Terapia Física José Oliver De Leo Jiménez**, estudiante de la Universidad Autónoma de Querétaro en la maestría de Ciencias en la Rehabilitación del Movimiento Humano bajo el protocolo de investigación “Correlación de la resonancia magnética cuantitativa y el desarrollo motor de niños de 8 años con factores de riesgo para daño cerebral perinatal”. Esto con fines académicos y de investigación, bajo la tutela del Dr. Manuel Hinojosa Rodríguez.

Sin otro particular, agradezco de antemano la atención que se sirva brindar al presente, al tiempo que le envío un muy cordial saludo.

Atentamente
“POR MI RAZA HABLARÁ EL ESPÍRITU”
Campus UNAM Juriquilla, Qro., 11 de febrero del 2020


DRA. THALÍA HARMONY BAILLET
Jefa de la Unidad de Investigación Neurodesarrollo
Investigador Titular “C”

• Blvd. Juriquilla -3001 • Col. Juriquilla • C.P. 76230 • Campus UNAM Juriquilla • Querétaro, Qro.
• Tel. (55) 56234201, (442)1926101

Anexo II: Constancia de participación en congreso ICEV 2021.



The Organizing Committee acknowledges the participation of
Salvador Calderon-Uribe, Jose Oliver De Leo Jimenez, Luis A. Morales-Hernandez, Irving A. Cruz-Albarran

for the presentation of the contribution titled
“Automatic Segmentation of Lateral Ventricles in MRI of Pediatric Patients from 4 To 12 Months”

at the
**IEEE International Conference on Engineering Veracruz 2021
(IEEE ICEV 2021)®**

Boca del Rio, Veracruz, October 25th - 28th, 2021


Dr. Angel Eduardo Gasca Herrera
DGAAT, Universidad Veracruzana


Dr. Darwin Mayorga Cruz
COVEICYDET


Ing. Cesar Pineda Moreno
IEEE Sección Veracruz



Anexo III: Constancia de participación en congreso CONIIN 2022.



CONiIN
XVIII INTERNATIONAL ENGINEERING
CONGRESS

THE QUERÉTARO STATE UNIVERSITY THROUGH THE ENGINEERING
FACULTY GRANT THE PRESENT ACKNOWLEDGMENT TO:

**Salvador Calderón-Uribe, Luis A. Morales - Hernández, Irving A. Cruz - Albarrán,
Carlos A. Pérez - Ramírez and Uriel Calderón-Uribe**

CONFERENCE:

**An FPGA-based embedded system for feature extraction of the lateral ventricles in
magnetic resonance images**

QUERÉTARO, MEX.
MAY 2022


Dr. Manuel Toledano Ayala
PRINCIPAL
ENGINEERING FACULTY


Dr. Gonzalo Macías Bobadilla
GENERAL COORDINATOR CONIIN
ENGINEERING FACULTY

Anexo IV: Constancia de participación en FOPER "Diseño de una estructura digital para la detección de alteraciones neurológicas en lactantes."



La Universidad Autónoma de Querétaro
y la Dirección de Atención a la Comunidad Universitaria
otorgan el presente

RECONOCIMIENTO

a

CALDERÓN URIBE SALVADOR

Por su participación como
RESPONSABLE DE PROYECTO

FOPER 2021

"Fondo de Proyectos Especiales de Rectoría"

Santiago de Querétaro, Qro., mayo de 2022.

Dra. Margarita Teresa de Jesús García Gasca
RECTORA

Lic. Verónica Núñez Perusquía
TITULAR DE LA DIRECCIÓN DE ATENCIÓN
A LA COMUNIDAD UNIVERSITARIA

