



**Universidad
Europea**

UNIVERSIDAD EUROPEA DE MADRID

ESCUELA DE ARQUITECTURA, INGENIERÍA Y DISEÑO

GRADO EN INGENIERÍA BIOMÉDICA

PROYECTO FIN DE GRADO

**OBTENCIÓN DE PARÁMETROS DE UN MODELO
PARA EL MOVIMIENTO DE LÍQUIDO
CEFALORRAQUÍDEO MEDIANTE REDES
NEURONALES USANDO DATOS DE SEÑALES REALES**

César Carrasco Pérez

Dirigido por

Dra. Ana Medina Palomo

CURSO 2024/2025

TÍTULO: Obtención de parámetros de un modelo para el movimiento de líquido cefalorraquídeo mediante redes neuronales usando datos de señales reales

AUTOR: César Carrasco Pérez

TITULACIÓN: Grado en Ingeniería Biomédica

DIRECTOR/ES DEL PROYECTO: Dra. Ana medina Palomo

FECHA: Diciembre de 2025

RESUMEN

Este proyecto aborda el estudio del movimiento del líquido cefalorraquídeo (LCR), un aspecto clave para comprender su dinámica y su relación con enfermedades neurológicas. La investigación se centra en el desarrollo un modelo basado en Redes Neuronales (RRNN) para analizar los datos obtenidos de imágenes reales de resonancia magnética (RM). Estas imágenes fueron segmentadas utilizando herramientas de software de ingeniería como ITK.Snap, Matlab y Rstudio para extraer parámetros tales como el volumen y flujo oscilatorio del LCR, permitiendo modelar su comportamiento en diversas condiciones fisiológicas y patológicas. Cabe destacar que el proyecto no se realizó en colaboración con ninguna empresa.

Los principales resultados incluyen la implementación de una red neuronal capaz de predecir patrones complejos en el flujo del LCR, con métricas bajas y resultados satisfactorios. Además, se simulaban parámetros alterados, como la elasticidad y resistencia, demostrando su impacto en la dinámica del flujo. Este proyecto confirma la utilidad de herramientas basadas en inteligencia artificial como alternativas no invasivas y de menor coste para el diagnóstico médico.

Los resultados obtenidos abren nuevas líneas de investigación en el análisis del LCR y destacan la relevancia de aplicar metodologías innovadoras para optimizar el estudio y tratamiento de afecciones relacionadas con el sistema nervioso.

Palabras clave: líquido cefalorraquídeo, redes neuronales, resonancia magnética, segmentación de imágenes, diagnóstico médico, RRNN, RM.

ABSTRACT

This project addresses the study of cerebrospinal fluid (CSF) motion, a key aspect for understanding its dynamics and relationship with neurological diseases. The research focuses on developing a neural network-based model to analyze data obtained from real magnetic resonance imaging (MRI). These images were segmented using engineering software tools such as ITK-Snap, Matlab and Rstudio to extract parameters such as CSF volumen and oscillatory flow, enabling the modeling of its behavior under various physiological and pathological conditions. It is worth that this project was not conducted in collaboration with any company.

The main results include the implementation of a neural network capable of predicting complex patterns in CSF Flow, with low error metrics and satisfactory outcomes. Additionally, altered parameters such as elasticity and resistance were simulated, demonstrating their impact on flow dynamics. This project confirms the utility of artificial intelligence-based tools as non-invasive and cost-effective alternatives for medical diagnosis.

The results obtained open new lines of research in CSF analysis and highlight the relevance of applying innovative methodologies to optimize the study and treatment of conditions related to the nervous system.

Keywords: cerebrospinal fluid, neural networks, magnetic resonance imaging, image segmentation, medical diagnosis, NN, MRI.

AGRADECIMIENTOS

Quiero agradecer a mi padre Antonio y a mi madre Soledad, por su confianza en mí y por hacer todo lo posible para que pudiera estudiar.

Agradezco también a mi tutora, la Dra. Ana Medina Palomo, por su paciencia y orientación a lo largo de este proyecto.

Finalmente, gracias a mis compañeros Manu y Óscar, por acompañarme durante la carrera y sacarme una sonrisa en los momentos cotidianos.

“El hombre que mueve montañas comienza cargando pequeñas piedras.”

Confucio

TABLA RESUMEN

	DATOS
Nombre y apellidos:	César Carrasco Pérez
Título del proyecto:	Obtención de parámetros de un modelo para el movimiento de líquido cefalorraquídeo mediante RRNN usando datos de señales reales.
Directores del proyecto:	Dra. Ana medina Palomo
El proyecto se ha realizado en colaboración de una empresa o a petición de una empresa:	NO
El proyecto ha implementado un producto: (esta entrada se puede marcar junto a la siguiente)	NO
El proyecto ha consistido en el desarrollo de una investigación o innovación: (esta entrada se puede marcar junto a la anterior)	SI
Objetivo general del proyecto:	Estudio del movimiento y obtención de parámetros del LCR mediante redes neuronales usando datos de señales reales.

Índice

RESUMEN	3
ABSTRACT	4
TABLA RESUMEN	7
Capítulo 1. RESUMEN DEL PROYECTO	14
1.1 Contexto y justificación.....	14
1.2 Planteamiento del problema	14
1.3 Objetivos del proyecto.....	14
1.4 Resultados obtenidos	14
1.5 Estructura de la memoria	14
Capítulo 2. MARCO TEÓRICO.....	15
2.1 Introducción.....	15
Capítulo 3. ANTECEDENTES / ESTADO DEL ARTE	21
3.1 Estado del arte	21
3.2 Contexto y justificación.....	22
3.3 Planteamiento del problema	23
Capítulo 4. OBJETIVOS.....	24
4.1 Objetivos generales	24
4.2 Objetivos específicos	24
4.3 Beneficios del proyecto	25
Capítulo 5. DESARROLLO DEL PROYECTO	26
5.1 Planificación del proyecto.....	26
5.2 Descripción de la solución, metodologías y herramientas empleadas.....	27
5.3 Recursos requeridos	53
5.4 Presupuesto	54
5.5 Viabilidad	55
5.6 Resultados del proyecto	56
Capítulo 6. DISCUSIÓN.....	58
6.1 Discusión Interpretativa de los resultados	58
6.2 Discusión autodescriptiva del proyecto.....	58

Capítulo 7.	CONCLUSIONES	60
7.1	Conclusiones del trabajo.....	60
7.2	Conclusiones personales.....	60
Capítulo 8.	FUTURAS LÍNEAS DE TRABAJO	61
Capítulo 9.	REFERENCIAS.....	62
Capítulo 10.	ANEXOS	64
10.1	Código Implementación Matlab	64
10.2	Código Modelo red neuronal h2o.....	65
10.3	Código Modelo red neuronal neuralnet	66

Índice de Figuras

Ilustración 1 Imagen esquema anatómica ilustrativa [4].....	16
Ilustración 2 Imagen de las distintas capas del tejido conectivo [5].....	17
Ilustración 3 Imagen ilustrativa MRI Diferencia anatómica LCR cervical -lumbar	18
Ilustración 4 Imagen de Resonancia Magnética Comercial de Philips	19
Ilustración 5 Relajación T1- Relajación T2[11]	20
Ilustración 6 Registro de Imágenes en T2 y T1 [12]	20
Ilustración 7 Imágenes de resonancia magnética corte transversal y longitudinal	27
Ilustración 8 Contraste de Autoajuste.....	27
Ilustración 9 Contraste de forma manual	28
Ilustración 10 Resultado del Contraste	28
Ilustración 11 Imagen Referencia del corte	29
Ilustración 12 Ajuste Manual de la densidad	30
Ilustración 13 Visualización de la pre-segmentación por el método Thresholding	30
Ilustración 14 Región de las cervicales – Región del tórax	31
Ilustración 15 Región del tórax corte longitudinal – Región lumbar	31
Ilustración 16 Evolución de las burbujas de segmentación	31
Ilustración 17 Resultado de las burbujas de segmentación.....	32
Ilustración 18 Problemas de las burbujas de segmentación.....	32
Ilustración 19 Segmentación manual Antes- Después.....	33
Ilustración 20 Segmentación manual Antes – Después	33
Ilustración 21 Segmentación manual Antes - Después	34
Ilustración 22 Volumen obtenido del LCR por ITK-Snap	34
Ilustración 23 Segmentación de la segunda MRI	35
Ilustración 24 Antes -Después segunda MRI.....	35
Ilustración 25 Volumen de la segunda MRI.....	35
Ilustración 26 Código de Importación y visualización del volumen en Matlab.....	36
Ilustración 27 Importación del volumen a Matlab.....	36
Ilustración 28 Visualización por cortes transversales	36
Ilustración 29 Código delimitación del perímetro del LCR.....	37

Ilustración 30 Código implementación parámetros del tamaño de los voxels	37
Ilustración 31 Parámetros de dimensiones de los voxels	38
Ilustración 32 Código filtrado de pixeles	38
Ilustración 33 Código obtención volumen	39
Ilustración 34 Sección transversal medula espinal, tractos de fibras	41
Ilustración 35 Flujo LCR valores normales	41
Ilustración 36 Nodos Análisis de patrones Observados	42
Ilustración 37 Gráficas con parámetros de Resistencia y Elasticidad bajos	43
Ilustración 38 Gráficas parámetros de Resistencia y Elasticidad altos	44
Ilustración 39 Esquema Red Neuronal [18]	45
Ilustración 40 Conjunto de datos de la red	46
Ilustración 41 Resultados Red Neuronal Modelo h2o columna V1	48
Ilustración 42 Resultados Red Neuronal Modelo h2o columna V9	48
Ilustración 43 Plot red neuronal visualización neuralnet	49
Ilustración 44 Primer resultado modelo neuralnet	52
Ilustración 45 Segundo resultado modelo neuralnet	52
Ilustración 46 Tercer resultado modelo neuralnet	53

Abreviaturas

- **LCR:** Líquido cefalorraquídeo
- **MRI:** Imagen por Resonancia Magnética
- **PIC:** Presión intracraneal
- **RRNN:** Redes Neuronales
- **MSE:** Error cuadrático medio
- **MAE:** Error absoluto medio
- **RMSE:** Raíz del error cuadrático medio
- **NIR:** No Information Rate
- **ACC:** Accuracy (Exactitud)
- **SNC:** Sistema Nervioso central
- **SNP:** Sistema Nervioso periférico

Índice de Tablas

Tabla 1 Matriz de Confusión 50

Tabla 2 Tabla Presupuesto 55

Capítulo 1. RESUMEN DEL PROYECTO

1.1 Contexto y justificación

El estudio y la comprensión de cómo funciona el líquido cefalorraquídeo en nuestro cuerpo es un paradigma que es de gran relevancia para el tratamiento y diagnóstico de diversas enfermedades relacionadas.

En contexto, para estudiar el LCR, realizar un modelo de red neuronal nos puede ayudar a identificar patrones complejos del flujo oscilatorio del líquido.

1.2 Planteamiento del problema

Este proyecto hace frente a un problema latente en la actualidad, la necesidad de un diagnóstico temprano para afecciones relacionadas con el sistema nervioso. Asimismo, el coste de adquisición y diagnóstico es elevado. Una mayor comprensión de cómo funciona la dinámica del LCR, servirá de antecedente para entender y evaluar futuros riesgos

1.3 Objetivos del proyecto

El objetivo general del proyecto consiste en estudiar el movimiento del líquido cefalorraquídeo, es decir, como funciona, segmentar LCR a través de imágenes de resonancia magnéticas reales y realizar un modelo de red neuronal.

1.4 Resultados obtenidos

Se logró segmentar imágenes de resonancia magnética para analizar el líquido cefalorraquídeo, obteniendo parámetros como el volumen y flujo mediante modelos computacionales. Se consiguió realizar un análisis de los patrones oscilatorios y su relación con la presión intracraneal. Asimismo, se consiguió implementar dos modelos de redes neuronales con resultados satisfactorios. Estos resultados validan el uso de herramientas basados en inteligencia artificial como alternativa no invasiva al estudio, comprensión y diagnóstico de enfermedades del LCR.

1.5 Estructura de la memoria

En primer lugar, se contextualiza y justifica el proyecto mediante un estudio del LCR y como se obtienen las imágenes con las que se va a trabajar en él. A continuación, se profundizará en los objetivos, seguidamente se describirá detalladamente el desarrollo del proyecto y por último concluyendo con una discusión de los resultados obtenido y futuras líneas de trabajo.

Capítulo 2. MARCO TEÓRICO

2.1 Introducción

El estudio del líquido cefalorraquídeo (LCR) es fundamental para comprender la dinámica del Sistema Nervioso Central (SNC) y su relación con diversas patologías neurológicas. Este capítulo aborda la anatomía básica del SNC, el rol del LCR y la adquisición de imágenes por resonancia magnética (MRI), con énfasis en las estructuras clave para este trabajo.

2.1.1 Explicación Anatómica

Se denomina sistema nervioso al conjunto de órganos y estructuras de control e información del cuerpo humano, constituido por células altamente diferenciadas, conocidas como neuronas, capaces de transmitir impulsos eléctricos entre sus terminaciones. [1]

Este sistema de transmisión de energía química y eléctrica recorre el cuerpo entero y permite la coordinación de movimientos y acciones. Acciones conscientes como inconscientes, a partir del cual se distinguen dos tipos de sistema nervioso: el somático y el autónomo. El primero se ocupa de la conexión entre las extremidades del cuerpo y el cerebro, mientras que el segundo lo hace de las acciones reflejas e involuntarias.[1]

El sistema nervioso cumple con una serie de funciones esenciales en el organismo:

1. Función sensorial: percibe los estímulos internos y externos a través de las neuronas receptoras.
2. Función motora: Se encarga de realizar una respuesta a través de los músculos.
3. Función integradora: Permite almacenar y recuperar información en la memoria, tomando decisiones basadas en el análisis de la información sensorial captada.[2], [3]
4. Regulación de procesos involuntarios: Controla funciones como la frecuencia cardíaca, liberación de hormonas, la respiración.[3]
5. Control y coordinación del cuerpo: Se ocupa de realizar instrucciones en las funciones del organismo, desde el movimiento muscular, esquelético, hasta el sueño, la digestión.[3]
6. Regulación del pensamiento y de las emociones: El sistema nervioso influye en la percepción y la interpretación de la realidad.[4] [3]

El sistema nervioso se divide según su forma estructural:


- SNP: Sistema Nervioso Periférico, compuesto por los nervios espinales y craneales, nervios y plexos viscerales. Es todo tejido nervioso fuera del SNC.
- SNC: Sistema Nervioso Central: compuesto por el encéfalo y la médula espinal. [4]

Anatómicamente:

Sistema nervioso central (SNC):
Encéfalo y Médula espinal

Sistema nervioso periférico (SNP):
Todo el tejido nervioso fuera del SNC

- SNC



- SNP

Ilustración 1 Imagen esquema anatómica ilustrativa [4]

Las meninges cumplen con una labor esencial, la sustentación y protección del encéfalo y la médula espinal. Las meninges, dividido en tres capas de tejido conectivo (duramadre, piamadre y aracnoides) ofrecen una defensa química, evitando infecciones por la entrada de patógenos al SNC, y mecánica con la ayuda del LCR amortiguando golpes que pueda sufrir:

- **Duramadre:** es la capa más externa, gruesa y resistente. También llamada como paquimeninge.
- **Aracnoides:** es la capa intermedia, blanda y esponjosa. Es un tejido avascular formada por fibras elásticas y colágenas.
- **Espacio subaracnoideo:** entre la aracnoides y la piamadre. Contiene el LCR
- **Piamadre:** es la capa más interna, fina y muy vascularizada. Recubre todas las circunvalaciones de la superficie del encéfalo.




Ilustración 2 Imagen de las distintas capas del tejido conectivo [5]

2.1.2 El líquido ceforraquídeo

El líquido ceforraquídeo (LCR) es un líquido transparente e incoloro que ocupa el sistema ventricular, los espacios subaracnoideos cerebrales y espinales y los espacios perivascuales en el SNC. El líquido es una mezcla de agua, proteínas a bajas concentraciones, iones, neurotransmisores y glucosa que se renueva de tres a cuatro veces al día. [6].

Sus principales funciones son además de el sostén y protección son la capacidad de mantener el ambiente químico óptico para el correcto funcionamiento del SNC. Sirve de medio de intercambio entre las neuronas y la sangre, ofreciéndoles nutrientes y recogiendo sustancias de desecho producidas [7].

2.1.3 Producción del LCR

El líquido ceforraquídeo (LCR) representa el 10% del volumen intracraneal. Este es producido principalmente por los plexos coroideos y reabsorbido en las vellosidades aracnoideas. Su secreción está asociada al transporte de iones y agua a nivel de la barrera hematoencefálica y sangre. La circulación del LCR está estrechamente relacionada con la frecuencia cardíaca y respiratoria. Del equilibrio entre estos procesos depende la presión intracraneal (PIC). [8].

2.1.4 Flujo oscilatorio del LCR

Para comprender como funciona el flujo oscilatorio del LCR, tenemos que indagar en una teoría muy aceptada denominada Monroe-Kellie, es un concepto fundamental en el campo de la neurología y neurocirugía que describe la relación entre los volúmenes de sangre, cerebroespinal y tejido cerebral dentro del SNC.

La teoría establece que cualquier aumento en el volumen de uno, influye en la disminución del otro, para mantener una presión intracraneal constante (PIC).[9].

Dicho de otra forma, la presión intracraneal (PIC) es la responsable que se mueva el LCR. Este movimiento es más rápido y fuerte, cerca del cráneo a diferencia de más abajo en la zona lumbar. Este movimiento va a estar influenciado también por la geometría del canal. Donde el canal es más estrecho la velocidad de flujo es mayor, y donde es más ancho va a ser más despacio.

Durante la sístole (contracción del musculo cardíaco del corazón), el LCR se mueve hacia abajo, a lo que denominaremos **caudal**, mientras que durante la diástole (relajación del musculo cardíaco del corazón) el líquido se mueve hacia arriba, a lo que denominaremos **cefálico**. [10]

Por lo tanto, concluimos que el flujo caudal del LCR tiene velocidades más altas y en consecuencia una duración menor que el flujo cefálico.



Ilustración 3 Imagen ilustrativa MRI Diferencia anatómica LCR cervical -lumbar

2.1.5 Resonancia Magnética

Las imágenes de Resonancia Magnética es una técnica no ionizante, con capacidad tridimensional excelente para observar el contraste para tejidos blandos, con alta resolución espacial. [11]

Anteriormente esta técnica era denominada como NMR (Nuclear Magnetic Resonance), sin embargo, se decidió quitar la palabra “nuclear” debido a las malas connotaciones negativas que tenía la población (nuclear reactors, atomic boom, etc.). En 1986 se cambió el nombre de NMR a MRI, a causa del accidente de Chernóbil.[11]

La técnica de RMI se basa en la medición de las propiedades magnéticas de los tejidos, en especial de los protones (núcleos de hidrógeno) presentes en el agua, y en menor medida en los lípidos. La técnica mide el contenido de hidrogeno de los voxels individuales de cada corte transversal del paciente. [11]



Ilustración 4 Imagen de Resonancia Magnética Comercial de Philips

2.1.6 Obtención de Imágenes Reales de Resonancia Magnética

Para la obtención de el volumen de la imagen de un paciente se realiza un procedimiento en el cual se acuesta al paciente en una mesa monitorizada véase en la figura anterior, la cual luego se desplazará hacia adentro del escáner tubular que produce un campo magnético estático muy intenso entre (1-3T) (T significa Teslas que es la magnitud con la cual se mide el campo magnético). Cuando los protones están rodeados del campo magnético, estos se alinean con dicho campo, seguidamente el escáner emitirá una señal de pulso a través del cuerpo, que momentáneamente impulsará a los protones a desalinearse. Al cesar la energía del pulso de frecuencia, la energía absorbida es reemitida en forma de señal. A medida que los protones se alinean con el campo magnético, liberan esta energía que será la señal captada. La intensidad de la señal varía según el tejido. [11]

Los aparatos de RMI registran estas señales, las cuales luego serán procesadas por una computadora para analizarlas y reproducir imágenes.

La intensidad de señal que emiten los tejidos va a depender, entre otros factores, de la relajación T1 y T2 de los átomos de H⁺ que los conforman.

2.1.6.1 Fenómeno de relajación

Al realizar una excitación de pulso, los protones excitados van a volver a su posición inicial original liberando la energía absorbida. Existen dos componentes dentro de la relajación, aunque ocurran al mismo tiempo se descomponen en función de sus ejes de orientación:

- Relajación longitudinal o T1: Depende de las interacciones del átomo con su entorno. Es de mayor duración.

- Relajación transversal o T2: Depende de las interacciones de los átomos entre sí. Es el desfase de los protones y de menor duración.




Ilustración 5 Relajación T1- Relajación T2[11]

Es decir, las imágenes se van a ver afectadas si aumentamos o disminuimos los tiempos de señal para modificar tanto T1 como T2.

Para identificar en una resonancia líquidos, como los átomos van a estar más separados y en continuo movimiento, lo que conlleva que el protón le será más difícil de encontrar a otro para cederle su energía. Aplicaremos tiempos de T1 y T2 largos, de 2-3 segundos, ya que son relajaciones lentas.[11]




Ilustración 6 Registro de Imágenes en T2 y T1 [12]

Como se puede apreciar en la figura anterior, es un ejemplo en el cual en muchas aplicaciones de imágenes es necesario comparar píxel a píxel dos imágenes del mismo campo obtenidas por el mismo sensor, pero en distinto tiempo. [12]

Capítulo 3. ANTECEDENTES / ESTADO DEL ARTE

3.1 Estado del arte

Para poder entender el desarrollo del proyecto, antes es necesario realizar una investigación documental para examinar trabajos previos relacionados con la temática. Esta búsqueda servirá como herramienta para adquirir conocimientos teóricos y metodológicos, permitiendo contextualizar el proyecto.

- **Inteligencia artificial aplicada en el ictus isquémico agudo: de niño a anciano.**[13].

En esta revisión se utilizó el uso de sistemas de IA para ayudar a categorizar, pronosticar y analizar pacientes con afecciones de ictus isquémico. Utilizando el aprendizaje automático y en particular el aprendizaje profundo (*Deep Learning*) que utilizan las redes neuronales convolucionales (CNN).

Este artículo muestra un efecto positivo sobre el uso de IA sobre componentes que influyen en la homeostasis del sistema nervioso, señalizando que es una herramienta integrante de parte práctica que ayuda a los neuroradiólogos, mediante análisis preliminares y antes de un diagnóstico general. Aunque destaca una reducción significativa en el tiempo entre diagnóstico y tratamiento, el artículo señala limitaciones como falsos positivos que requieren intervención del neuroradiólogo para un diagnóstico final.

- **Uso de la inteligencia artificial para predecir la hipertensión intracraneal en pacientes después de una lesión cerebral traumática: una revisión sistemática.**[14]

En este estudio cuyo enfoque es la prevención frente a la hipertensión intracraneal, utilizan modelos de aprendizaje automático para la predicción. En él se compararon distintos modelos con distintos procesos para evaluar y comparar la especificidad, sensibilidad y exactitud entre modelos.

- **Enfoques de aprendizaje automático para la predicción de la presión intracraneal en pacientes con lesión cerebral traumática: una revisión sistemática.** [15]

En esta revisión sistemática cuyo propósito es minimizar la tasa de lesiones cerebrales secundarias y mejorar los resultados de los pacientes con lesiones cerebrales traumáticas para facilitar la intervención oportuna antes de una crisis, lo realiza a través de una metodología en la que primeramente evalúan estudios de precisión diagnóstica, revisadas posteriormente y evaluaron el método de predicción de crisis de la presión intracraneal en pacientes con lesiones traumáticas cerebrales. En la que destacaron procesos de *Machine Learning* como modelos de regresión logística, procesos gaussianos entre otros. Concluyendo que en la medida de como los algoritmos son

capaces de mejorar la atención al paciente, así como una reflexión ética legal y social de cómo debería de implementarse.

- **Dinámica del líquido cefalorraquídeo y elevación de la presión intracraneal de enfermedades neurológicas.** [16]

En este artículo se describe la dinámica del LCR y su relación con la presión intracraneal en enfermedades neurológicas. Examina factores como la secreción de LCR, su regulación a través de la barrera hematoencefálica y los gradientes osmóticos y de presión. Este tipo de artículos ayuda a la comunidad científica a una mejor comprensión del campo de la medicina interna, para favorecer la aplicación de la ingeniería en ella.

A partir de la revisión bibliográfica y el análisis del contexto clínico, queda claro que el estudio del LCR a través de métodos tradicionales presenta limitaciones significativas. Este proyecto se propone desarrollar un modelo de red neuronal que no sola permita modelar dinámicas complejas del LCR, sino que también aporte una herramienta accesible y no invasiva para el diagnóstico temprano.

3.2 Contexto y justificación

Comprender y modelar el movimiento del LCR es de gran importancia para el diagnóstico y tratamiento de enfermedades neurológicas, como la hidrocefalia, *Chiari tipo I*, hernias cefálicas y lesiones traumáticas cerebrales entre otras.

Las redes neuronales artificiales son una herramienta para modelar sistemas complejos como el movimiento del LCR. Estas pueden aprender patrones a partir de un conjunto de datos y generar predicciones precisas sobre el comportamiento del sistema.

En contexto para estudiar el LCR, las redes neuronales pueden estimar parámetros de modelos físicos, es decir pueden aprender parámetros de ecuaciones diferenciales que pertenecen a la dinámica del LCR, a partir de datos de señales reales, como la velocidad de flujo o la presión (PIC). Las redes neuronales pueden identificar patrones complejos en el movimiento del LCR que son difíciles de encontrar con métodos tradicionales. Además, se emplea como una técnica innovadora como método de diagnóstico y tratamiento.

Este proyecto propone desarrollar un modelo de red neuronal para estimar los parámetros del movimiento del LCR a partir de datos de señales reales de resonancia magnética en la cual se segmentará para obtener los datos necesarios para crear el modelo.

En relación con el campo de la medicina, la tecnología avanza y las técnicas tradicionales para estudiar el movimiento del LCR son costosas, invasivas y proporcionan información limitada.

Este proyecto ofrece una alternativa prometedora para estudiar el movimiento del LCR de manera más precisa y eficiente, cubriendo una necesidad de mejorar los métodos de estudios frente a los convencionales. Tiene potencial para mejorar el diagnóstico y tratamiento de enfermedades neurológicas, un mejor conocimiento sobre los datos puede llegar a conducir a nuevos métodos de diagnóstico y tratamiento para enfermedades relacionadas con el flujo del

LCR. Asimismo, este proyecto contribuirá al avance del campo de la inteligencia artificial en el área de la ingeniería biomédica.

Es decir, este proyecto cuyo objetivo está centrado en el desarrollo de una red neuronal con foco al área de la investigación, se justifica por la necesidad de mejorar los métodos para estudiar el flujo del LCR, con potencial para mejorar el diagnóstico y tratamiento de enfermedades neurológicas.

3.3 Planteamiento del problema

Este proyecto hace frente a un problema latente en la actualidad, la necesidad de un diagnóstico temprano para enfermedades relacionadas con el sistema nervioso y más específicamente relacionadas con el LCR. Enfermedades como la hidrocefalia, hernias cefálicas, posibles tumores en estadios tempranos...

Los principales problemas que concierne en este tipo de enfermedades son síntomas tempranos, sutiles, inespecíficos y fácilmente confundibles con otras afecciones. En el caso de las personas mayores con el envejecimiento. El estigma asociado a las enfermedades relacionadas con el LCR y la falta de conciencia y conocimiento sobre ellas, pueden disuadir a las personas de buscar atención médica y participar en programas de detección.

Una mayor comprensión de la relación del LCR y las enfermedades del SNC proporcionará una mejor comprensión de la aparición y el progreso de estas: meningitis, hemorragia subaracnoidea, esclerosis múltiple y neoplasias.

Enfermedades que aparecen conforme la edad produciéndose una hiposecreción fisiológica del LCR debido al aumento de la cantidad de tejido conectivo entre la vasculatura y las células epiteliales.[6]

También la aparición de enfermedades neurodegenerativas como por ejemplo el Alzheimer, se ha relacionado con la atenuación de sistemas de eliminación de residuos. Se presupone que estas proteínas son eliminadas por el sistema de eliminación de desechos, por lo que la reducción del movimiento del flujo del LCR podría facilitar la acumulación de proteínas en el cerebro.[6]

Si bien la investigación ha avanzado en la comprensión de estas enfermedades, la detección temprana sigue siendo un desafío importante.

Aunque no existen estadísticas precisas sobre el número de personas en España con enfermedades específicas relacionadas con el LCR, se estima que 1 de cada 413 personas sufre o sufrirá una afección neurológica (INE, SEN, OMS). Estas cifras reflejan la necesidad de avanzar en métodos de diagnóstico temprano, especialmente para enfermedades donde el LCR juega un papel crucial, como la hidrocefalia o las lesiones traumáticas.

Capítulo 4. OBJETIVOS

4.1 Objetivos generales

El objetivo principal del proyecto es analizar y segmentar imágenes de resonancia magnética para extraer datos reales y desarrollar un algoritmo basado en redes neuronales que permita modelar la dinámica del líquido cefalorraquídeo. Este enfoque utiliza herramientas de desarrollo software ampliamente reconocidas en el ámbito de la ingeniería biomédica, como ITK-Snap, Matlab y Rstudio.

Objetivos generales:

- Mejorar la comprensión de la dinámica del líquido cefalorraquídeo.
- Detectar y predecir patrones anormales en el flujo del líquido cefalorraquídeo
- Identificar signos tempranos de enfermedades neurológicas relacionadas con el líquido cefalorraquídeo.
- Validar la precisión del modelo utilizando datos reales de señales de Resonancia Magnética.
- Contribuir a la optimización de tratamientos y pronósticos médicos proporcionando información detallada sobre el comportamiento del líquido cefalorraquídeo.
- Promover la colaboración interdisciplinar entre profesionales de la salud e ingenieros biomédicos.

4.2 Objetivos específicos

- Elaborar un estudio comprensivo sobre la anatomía y función del líquido cefalorraquídeo y su función dentro del sistema nervioso central.
- Relacionar el flujo oscilatorio del canal cerebro espinal con la presión intracraneal utilizando un modelo matemático.
- Segmentar y procesar las imágenes de resonancia magnética para extraer señales reales relacionados con el LCR.
- Interpretar los resultados obtenidos de la segmentación y procesamiento de imágenes relacionándolos con el flujo oscilatorio del LCR.
- Obtener parámetros de resistencia, elasticidad, geometría del canal espinal y presión intracraneal.
- Programar y entrenar un modelo de red neuronal para analizar la dinámica del LCR.
- Evaluar los resultados obtenidos y comparándolos con datos de referencia.
- Reentrenar y ajustar el modelo de red neuronal para mejorar la precisión y la capacidad de predicción.

Queda fuera del alcance de este proyecto el desarrollo de modelos de redes neuronales complejos con un elevado número de capas ocultas, así como la resolución de ecuaciones diferenciales que relacionen directamente la presión intracraneal con el volumen del LCR. Estas tareas se consideran complementarias a futuros desarrollos.

4.3 Beneficios del proyecto

Este proyecto propone una alternativa no invasiva y de menor coste frente a los métodos convencionales para analizar el LCR, proporcionando una herramienta adicional para el diagnóstico temprano y preciso de condiciones neurológicas. Su implementación podría contribuir significativamente al avance de la investigación clínica, ofreciendo un mejor entendimiento del comportamiento del LCR y su relación con diversas patologías. Además, esta tecnología, tiene potencial de optimizar tratamientos y mejorar pronósticos al proporcionar información detallada sobre el flujo y dinámica del LCR.


Obtención de parámetros de un modelo para el movimiento de líquido cefalorraquídeo mediante RRNN usando datos de señales reales.

César Carrasco Pérez

Capítulo 5. DESARROLLO DEL PROYECTO

5.1 Planificación del proyecto

En este diagrama de Gantt, se describe las tareas del Trabajo de Fin de Grado que se realizarán a lo largo de su desarrollo, indicando el tiempo correspondiente para realizar cada una de ellas. Este proyecto consta de 7 tareas principales, en las cuales se dividen en subtareas. En Azul se ha indicado las reuniones con la tutora del proyecto para poder evaluar el avance de este y recibir feedback. De la misma forma se indican en un verde más oscuro las tareas principales y en un verde más clarito las subtareas.



5.2 Descripción de la solución, metodologías y herramientas empleadas

El desarrollo de este proyecto se divide en dos etapas principales: segmentación y procesamiento de imágenes de resonancia magnética, y la programación de un modelo de red neuronal para predecir parámetros relacionados con el movimiento del LCR. A continuación, se describen las metodologías empleadas y los resultados obtenidos en cada etapa, destacando como contribuyen al cumplimiento de los objetivos planteados.

5.2.1 Proceso de segmentación a través de ITK-Snap

La segmentación se realizó utilizando ITK-Snap a partir de imágenes volumétricas en formato DICOM.




Ilustración 7 Imágenes de resonancia magnética corte transversal y longitudinal

Para estas imágenes no se llega a apreciar del todo secciones a segmentar, por ello se procederá a reajustar el contraste primero de forma automática y luego de forma manual para poder distinguir bien las secciones.




Ilustración 8 Contraste de Autoajuste




Ilustración 9 Contraste de forma manual




Ilustración 10 Resultado del Contraste




Ilustración 11 Imagen Referencia del corte

Una vez identificadas las partes, se lleva a cabo una pre-segmentación. En esta etapa, transformamos la imagen anatómica en una nueva imagen sintética llamada imagen velocidad.

La imagen velocidad tiene valores en el rango -1 a 1. El objetivo de la pre-segmentación es asignar valores de velocidad cercanos a 1 dentro de la estructura de interés y cercanos a -1 para otras partes de la imagen.

En el software de ITK-Snap hay cuatro modos de pre-segmentación:

- **Thresholding:** Los píxeles con intensidad dentro de un rango especificado por el usuario se asignan valores de velocidad positivos.
- **Clasificación:** Donde se dibujan ejemplos de dos o más tejidos en la imagen, y un algoritmo de aprendizaje automático, utiliza estos ejemplos para asignar valores de velocidad en el resto de la imagen.
- **Clustering:** Donde la imagen se divide automáticamente en dos o más clases de tejidos agrupando los píxeles de intensidad similares.
- **Edge attraction:** Este enfoque encuentra y acentúa los bordes en la imagen. La velocidad está cerca de 1 lejos de los bordes y cerca de 0 en los bordes.

En este caso utilizaremos el método de pre-segmentación de Thresholding.

En primera instancia ajustaremos de forma manual la densidad de la imagen para acaparar el mayor número de imágenes posibles.




Ilustración 12 Ajuste Manual de la densidad




Ilustración 13 Visualización de la pre-segmentación por el método Thresholding

Una vez ajustado los niveles de densidad, ajustamos y colocamos las semillas o también denominadas *bubbles* (burbujas) dentro de la región de la estructura de interés. Estas *bubbles* se expandirán para formar la segmentación de la figura.




Ilustración 14 Región de las cervicales – Región del tórax




Ilustración 15 Región del tórax corte longitudinal – Región lumbar

En esta etapa, las *bubbles* evolucionan, expandiéndose sobre las regiones de las partes positivas de la imagen velocidad construyéndose sobre las negativas.




Ilustración 16 Evolución de las burbujas de segmentación

A diferencia de la fase de pre-segmentación, que etiqueta píxeles individuales como probables objetos de interés o no, la fase de evolución produce un objeto o conjunto de estos contiguos basados en las *bubbles* colocadas por el usuario.

Esta fase se ha concluido con un total de 2251 iteraciones.

Step size:	Iteration:
1	2551

5.2.2 Resultados de la segmentación a través de ITK-Snap




Ilustración 17 Resultado de las burbujas de segmentación

Al finalizar el último proceso nos queda tal y como se observa en la figura. En ella se aprecia irregularidades, pues el LCR no es igual en todas sus partes. Sin embargo existen diversos errores en la segmentación automática.




Ilustración 18 Problemas de las burbujas de segmentación

Al realizar el proceso de thresholding debido al archivo de resonancia magnética, hay intensidades en las cuales, incluso incrementando y modificando el contraste no consiguen obtener velocidades cercanas a 1 y por lo tanto no segmentarse adecuadamente. Estos lugares se pueden apreciar pues debería seguir la geometría y su forma tal y como se observa en las figuras. Por ello se realizará una segunda segmentación manual sobre aquellas zonas en las que

debería de haber LCR, completando y obteniendo así una segmentación más sólida y consistente.




Ilustración 19 Segmentación manual Antes- Después

Una vez realizado la segmentación manual, se puede apreciar una mejoría consistente en la segmentación.




Ilustración 20 Segmentación manual Antes – Después




Ilustración 21 Segmentación manual Antes - Después

Aunque el LCR se produzca y exista volumen dentro del cerebro, para calcular el caudal y su volumen, no es relevante, por ello se eliminara la segmentación a partir de la primera vertebra C1 Atlas [5]

Como se puede apreciar en las ilustraciones 19 y 20 se eliminan el LCR que se halla por encima del Atlas.

Volumes and Statistics - ITK-SNAP				
	Label Name	Voxel Count	Volume (mm3)	Intensity Mean $\pm$ SD (SPINE)
0	Clear Label	66361784	8.762e+06	25.2618 $\pm$ 48.8365
1	LCR	650608	8.59e+04	479.0521 $\pm$ 229.3056

Ilustración 22 Volumen obtenido del LCR por ITK-Snap

La propia aplicación software permite calcular el volumen de la sección segmentada, véase en la ilustración 21. Todo este proceso es realizado para una imagen de resonancia magnética y obtener los parámetros que se necesitan.

Asimismo, se realizó el mismo proceso para una segunda imagen de resonancia magnética. Obteniendo más parámetros para nuestra futura red neuronal.




Ilustración 23 Segmentación de la segunda MRI




Ilustración 24 Antes -Después segunda MRI

	Label Name	Voxel Count	Volume (mm3)	Intensity Mean $\pm$ SD SPINE_Copmposing_1_ bueno
0	 Clear Label	67193081	8.872e+06	17.3756 $\pm$ 44.9742
1	 LCR	909637	1.201e+05	343.4409 $\pm$ 232.1114

Ilustración 25 Volumen de la segunda MRI

5.2.3 Proceso de adquisición de parámetros a través de Matlab

Los parámetros del LCR, como el volumen segmentado y la velocidad del flujo, se calcularon utilizando Matlab.

```
[Z,infoZ]=ReadData3D("LCR.mha");  
Z = permute(Z,[2 3 1]);  
figure, volshow(Z);  
figure,sliceViewer(Z)
```

Ilustración 26 Código de Importación y visualización del volumen en Matlab



Ilustración 27 Importación del volumen a Matlab




Ilustración 28 Visualización por cortes transversales

El volumen se obtuvo delimitando el perímetro del LCR en cada corte transversal y sumando las áreas correspondientes, ajustadas por el tamaño del voxel. Para estimar el flujo, se simuló la derivada temporal del volumen, ya que las imágenes de resonancia utilizadas no incluían datos temporales.

Estos cálculos son esenciales para identificar patrones relacionados con la dinámica del CLR y para entrenar la red neuronal en la detección de anomalías.

```
%BW PERIM  
BW=bwperim(Z,18);  
figure,sliceViewer(BW);
```




Ilustración 29 Código delimitación del perímetro del LCR

Como se observa en la imagen anterior, el procedimiento será establecer un perímetro por el cual se cuantificará el área dentro de los cortes en el eje Z para luego calcular el volumen total de todas las regiones.

```
% Parámetros iniciales del tamaño del voxel  
voxelX = 0.4063; % Tamaño del voxel en el eje X en mm  
voxelY = 0.4063; % Tamaño del voxel en el eje Y en mm  
voxelZ = 0.8; % Tamaño del voxel en el eje Z en mm
```

Ilustración 30 Código implementación parámetros del tamaño de los voxes.

En primer lugar, definimos el tamaño del voxel para cada eje, un voxel es la unidad cúbica que compone un objeto tridimensional. En este caso se trabajará en milímetros. Para saber los parámetros de las dimensiones de nuestra imagen obtenida a través de la segmentación, se consigue en la información de la estructura, exactamente en el campo de PixelDimensions. Como se puede observar en la siguiente ilustración:

infoZ		infoZ.PixelDimensions	infoZ.PixelDimensions		
1x1 struct with 17 fields			1	2	3
Field ^	Value		1	2	3
Filename	"LCR.mha"		0.4063	0.4063	0.8000
Format	'MHA'				
CompressedD...	'false'				
ObjectType	'image'				
NumberOfDi...	3				
BinaryData	'true'				
ByteOrder	'false'				
TransformMat...	[-1.2797e-21,1,4....				
Offset	[16.7903,-116.02...				
CenterOfRota...	[0,0,0]				
AnatomicalOr...	'ASL'				
PixelDimensi...	[0.4063,0.4063,0....				
Dimensions	[659,1784,57]				
DataType	'ushort'				
DataFile	'LOCAL'				
BitDepth	16				
HeaderSize	535				

Ilustración 31 Parámetros de dimensiones de los voxels

```
% Filtramos los componentes pequeños
Z = bwareaopen(Z,2);
```

Ilustración 32 Código filtrado de pixeles

Luego filtramos las pequeñas regiones que no son de interés en nuestra imagen binaria, es decir la función elimina los componentes conectados que tengan menos de 2 píxeles. Esto se utiliza para eliminar ruido o detalles insignificantes.

```
% Iteramos sobre cada corte en el eje Z
for z = 1:dimZ
    % Obtenemos el corte en cada eje Z
    slice = Z(:, :, z);

    % Obtenemos el perímetro de la región en el corte
    perimetro = bwperim(slice);

    % Rellenamos el área dentro del perímetro
    rellenar = imfill(perimetro, 'holes');

    % Calculamos el área (píxeles) dentro del perímetro relleno
    area = sum(rellenar(:));

    % Sumamos el área al volumen total en voxels
    volumenVoxels = volumenVoxels + area;
end

% Calculamos el volumen de cada voxel en unidades físicas
volumenPorVoxel = voxelX * voxelY * voxelZ;

% Ajustamos el volumen total a unidades físicas
volumen = volumenVoxels * volumenPorVoxel;

disp(['El volumen de la imagen 3D es aproximadamente ', ...
    num2str(volumen), ' mm3.']);
```

Ilustración 33 Código obtención volumen

A través del siguiente fragmento de código se obtiene el volumen de la imagen, el cual para obtener se realiza un bucle que recorra cada corte, encuentre los bordes del perímetro y luego los rellene. Para finalmente ir sumándole cada corte. Con esto tenemos el volumen el cual lo multiplicaremos por nuestra unidad de voxel para obtener una aproximación en una magnitud física.

El volumen de la imagen 3D es aproximadamente 104997.0219 mm³.

La cantidad de LCR que circula en una persona sana se encuentra entre los 100 -150ml que son 100.000 -150.000 mm³ expresado en unidad de volumen. Teniendo en cuenta que la segmentación tiene un corte a la altura de la primera vertebra (atlas- C1), habría cierta cantidad en ml que se han obviado para calcular el volumen de esta segmentación. Por lo tanto el resultado obtenido es más que optimo de considerar, ya que podemos deducir que dicha diferencia no deferiría del resultado obtenido, ya que no variaría dentro del rango obtenido para una persona sana normal.

5.2.4 Obtención del Flujo

Para calcular la velocidad del flujo del LCR, se toma la derivada temporal del volumen segmentado. La velocidad del LCR en una región específica del canal espinal está relacionada con la tasa de cambio del volumen en esa sección.

$$v(t) = \frac{dV(t)}{dt}$$

Siendo $V(t)$ el volumen en una sección particular en función del tiempo. (Anderson, John D. 1995)

Este proceso se realiza para cada intervalo de tiempo entre los puntos de adquisición de imágenes, de modo que se obtienen valores de velocidad en función del tiempo.

Sin embargo, la RM que se segmentó no es temporal, sino una estática (es decir capturada en un solo instante), entonces no es posible obtener directamente una gráfica de la velocidad del flujo del LCR. Debido a que se imposibilita realizar la derivada temporal, que es la variación del volumen a través del tiempo.

Por lo tanto, utilizaremos modelos computacionales de dinámica de fluidos para simular el flujo del LCR. Estos modelos combinan la anatomía estática obtenida con la información de los otros parámetros para estimar patrones de flujo.

5.2.5 Breve Inciso parámetros del modelo computacional

El líquido cefalorraquídeo se mueve de forma oscilatoria, subiendo y bajando de manera cíclica según el ritmo cardíaco. [9].

Este movimiento es más fuerte cerca del cerebro, en comparación con la zona lumbar, donde casi es nulo. Este movimiento es debido a la presión intracraneal, es decir a las diferencias de presión que se originan en las distintas partes del cráneo. Dicho de otra forma, la PIC es lo que origina que se mueva el LCR.

Este movimiento es influenciado por la **geometría del canal**; donde el canal es más estrecho la velocidad del flujo es mayor, y donde es más ancho la velocidad del flujo será menor.

Cada persona tiene una geometría ligeramente distinta, pero similar.

Asimismo, existen otros parámetros que influyen en el flujo, como la **elasticidad** que es un parámetro fisiológico que varía en función del tiempo, sin embargo, no varía demasiado a no ser que tenga una afección, lo que indicaría en el modelo que a través de este parámetro pueda predecir una enfermedad.

Y la **resistencia**, que ocurre por la dilatación de vasos sanguíneos o la forma de la estructura ósea de la columna vertebral, entre otros.




Ilustración 34 Sección transversal medula espinal, tractos de fibras

En la ilustración se puede apreciar que según la forma del tracto espinal y la cantidad de vasos sanguíneos o nervios infieren en la geometría y proporcionalmente en el volumen.

5.2.6 Resultados proceso de adquisición

5.2.6.1 Resultados proceso de adquisición valores normales

Esta gráfica representa como varía la velocidad del flujo del LCR en función del tiempo. La velocidad se mide en milímetros cúbicos partido segundos y se puede apreciar que cambia de signo lo que resalta que es un movimiento oscilatorio periódico. Similar al de los latidos cardiacos o la respiración. 2.1.4




Ilustración 35 Flujo LCR valores normales

La gráfica muestra un pico alto inicial seguido de una disminución de la velocidad a medida que el LCR se mueve hacia la zona lumbar, la velocidad disminuye ya que el flujo se aleja de la fuente de presión que ejercería el cerebro y también causado por la resistencia del canal espinal y los espacios intervertebrales que generan resistencia al flujo, especialmente en las zonas más bajas.

El pico de velocidad durante el primer segundo indica un aumento brusco de la velocidad, producido por la presión. Esto lo denominaremos fase rápida. Después de este pico, la velocidad oscila hacia valores negativos, debido a una disminución de la presión, lo que provoca que el LCR retroceda (hacia la zona caudal). El segundo pico representa un nuevo impulso en la misma dirección inicial (hacia el cerebro). Esto podría ser a una posible segunda oscilación en el ciclo de la presión, lo que genera un flujo adicional pero más débil.

Después del primer impulso el flujo disminuye, pero debido a las propiedades elásticas y rebote de los tejidos, el LCR tiende a avanzar, lo que podría explicar este segundo pico más pequeño.

Luego la disminución gradual en los siguientes segundos sugiere que el flujo pierde velocidad debido a que se encuentra en la zona lumbar y por tanto más alejado de donde se produce la presión.

La siguiente ilustración es una representación de los nodos Fourier para nuestro flujo, la cual nos permite descomponer el flujo en componentes de distintas frecuencias. El análisis de Fourier nos permite descomponer las complejas ondas de flujo en sus componentes sinusoidales fundamentales, lo que facilita cuantificar la magnitud y fase de los diferentes componentes.

Cada gráfica representa la velocidad del flujo del LCR en una sección particular de la columna a lo largo del tiempo.




Ilustración 36 Nodos Análisis de patrones Observados

La primera sección (representa la región cerca de C1) muestra una amplitud de velocidad más alta, con oscilaciones más pronunciadas, a medida que bajamos de secciones (es decir, hacia la región lumbar), la amplitud de las oscilaciones disminuyen. Dicha disminución indica que el flujo va perdiendo velocidad conforme se aleja de la zona cefálica. Esto es consistente ya que concuerda con la gráfica analizada anteriormente. Asimismo, se puede observar que en las últimas secciones la velocidad tiende a ser casi completamente nula.

La descomposición de Fourier ayuda a identificar cómo se comporta el flujo del LCR en diferentes puntos de la columna. En las primeras secciones, los componentes de alta frecuencia indican una respuesta rápida a los impulsos del PIC, mientras que, en las secciones inferiores, encontramos los compontes de baja frecuencia indicando que el flujo es más lento y menos variable.

Por tanto, podemos concluir que hay un desgaste del Flujo en dirección caudal.

5.2.6.2 Resultados proceso de adquisición valores alterados

Una vez analizado las anteriores graficas para pacientes sanos, nos preguntamos, ¿qué podríamos esperar de una persona afectada por una posible enfermedad? ¿Qué ocurriría si los parámetros varían? Para ello se expondrá dos ejemplos:




Ilustración 37 Gráficas con parámetros de Resistencia y Elasticidad bajos

Al observar estas gráficas podemos deducir que las oscilaciones son más suaves y prolongadas, esto es causado por su baja elasticidad ya que el flujo pierde menos energía con cada oscilación. Al reducir la elasticidad, el LCR no reacciona de igual manera ya que no existe una presión tan fuerte, moviéndose de manera más suave. Asimismo, al existir también menos resistencia lo que produce es que el LCR fluya mejor.

En las gráficas de las series de Fourier se puede observar que las oscilaciones son más uniformes, como el sistema no ofrece mucha resistencia las oscilaciones son más pronunciadas y no se disipan casi hasta llegar a la última sección. Este resultado es atípico en un sistema fisiológico, ya que se debería de disminuir la energía mucho antes. Lo que podemos predecir como una posible afección.




Ilustración 38 Gráficas parámetros de Resistencia y Elasticidad altos

Se observa que el primer pico es muy pronunciado, esto es debido a la alta elasticidad ya que el impulso del PIC se refleja de forma intensa tras almacenar suficiente energía elástica capaz de impulsar el LCR a gran velocidad. Asimismo, la aparición de dos picos en la segunda fase puede ser también, debido a su elasticidad ya que se mantiene oscilando tras un primer golpe de gran energía. Sin embargo, se puede apreciar muy bien en el análisis de Fourier la alta resistencia del flujo ya que podemos deducir que para la alta energía que recibe del PIC se amortigua relativamente rápido siendo que pierde velocidad de manera considerativa.

En este caso tener una alta elasticidad y resistencia podría inducir a que el paciente puede tener una afección, sin embargo, se complementan muy bien, ya que, aunque el flujo oscile muy rápido para lo que sería saludable, tener una alta resistencia beneficia a que este riesgo sea menos perjudicable para la salud. Este tipo de casos podría ser perfectamente un falso positivo para nuestro conjunto de datos para relacionar las posibles afecciones.

5.2.7 Red neuronal

Para la realización de la red neuronal, se trabajará a través del software de Rstudio. Este software permitirá trabajar con las bases de datos obtenidas.

Las Redes Neuronales Artificiales son modelos computacionales inspirados en las neuronas biológicas, debido a que están formadas por un conjunto de unidades (a las que llamaremos neuronas), las cuales están conectadas entre sí. Estas conexiones estarán definidas con unos pesos los cuales determinarán la importancia de dichas conexiones. Durante el aprendizaje o el entrenamiento de la red, los pesos se ajustan con el fin de producir una salida adecuada según la entrada en la que se aplique en la red. Las redes neuronales están compuestas por una capa de entrada, una o varias capas ocultas y una de salida. [17]




Ilustración 39 Esquema Red Neuronal [18]

Cada neurona realiza un cálculo matemático de la suma ponderada de las entradas con los pesos de la red, luego se aplica sobre dicho resultado una función de activación, que producirá la salida final de cada neurona y que servirán como valores de entrada de la siguiente capa de la red funcional.

Este proceso de aprendizaje se consigue gracias al algoritmo conocido como Feedforward, que consiste en aplicar las entradas en la red, obtener una salida final en la última capa y comparar con el resultado esperado, para luego ir modificando hacia atrás los pesos de las capas de salida, oculta y entrada respectivamente. Con el propósito de minimizar el error. Por lo tanto, cuantos más datos se consigan para entrenar a la red, mejores resultados se obtendrán. [18]

5.2.8 Descripción del conjunto de datos del modelo

Para nuestra red neuronal tendremos un conjunto de datos que estará compuesto por los parámetros adquiridos anteriormente.

- **G - Elasticidad:** Cuantifica la capacidad de la sección de la columna para recuperar su forma.
- **R – Resistencia:** Cuantifica la oposición de las fuerzas que resiste al flujo.
- **Parte Real e Imaginaria:** Extraídas del Análisis de Fourier, representan los valores complejos de las secciones de la columna. Cada par consecutivo corresponde a una sección del análisis. Siendo que cada conjunto de datos este compuesto por 22 columna. (11 parte real y 11 imaginaria). Teniendo un total de 418 columnas que son un total de 19 análisis.

	G	R	V3	V4	V5	V6
1	1.267000	-5.80890	0.500140	-5.38090	-0.1404000	-4.91950
2	0.655250	-0.95458	0.598610	-0.92460	0.5453500	-0.89157
3	0.921600	-3.54850	0.653660	-3.40290	0.4183400	-3.24480
4	0.521440	-2.41930	0.233630	-2.26030	-0.0096456	-2.08970
5	1.189400	-4.52120	0.466480	-4.10700	-0.1158600	-3.65680
6	5.007600	-3.40420	4.772000	-3.28630	4.5341000	-3.16050
7	0.160090	-0.67040	0.110420	-0.64336	0.0668220	-0.61391
8	0.859960	-2.90190	0.669090	-2.79810	0.4993100	-2.68400
9	0.597150	-2.31600	0.385930	-2.20110	0.2029800	-2.07800

Showing 1 to 9 of 4,202 entries, 420 total columns

Ilustración 40 Conjunto de datos de la red

5.2.9 Primer Modelo Implementado (Librería h2o)

La idea es implementar un modelo capaz de predecir las 22 variables mencionadas, para ello se utilizará un modelo de red neuronal profunda, de la librería h2o, con 419 neuronas de capa de entrada (una para cada columna, es decir variable predictora). Dos capas ocultas de 15 neuronas cada una y por último, la capa de salida (1 neurona). Con el objetivo de predecir cada iteración en las secciones correspondientes. Este obtendrá una capa de salida (una variable predicha) con lo que, mediante un bucle iterativo, repitiéndolo hasta 22 veces obtendremos una variable predicha para cada sección.

Se utilizó la librería h2o, ya que, tiene una avanzada capacidad computacional de procesamiento, siendo que tenemos una gran cantidad de datos, esta librería esta diseñada para manejar grandes volúmenes de datos de manera eficiente, (ya que trabaja en paralelo).

Para evaluar nuestro modelo, compararemos métricas como Error cuadrático medio (MSE), Error absoluto medio (MAE) y Raíz del error cuadrático medio (RMSE):

- El MSE mide el promedio de los errores al cuadrado entre las predicciones del modelo ($\hat{y}_i$) y los valores reales (y_i). Siendo su fórmula para calcularlo:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

El MSE es una métrica que penaliza fuertemente los errores grandes, ya que, en su fórmula, estos los eleva al cuadrado. Es muy útil para entender que tan lejos, en promedio, están las predicciones de los valores reales. [19]

En el modelo implementado indica qué tan bien está funcionando la red en cada columna. Si el MSE es bajo, significa que las predicciones están muy cerca de los valores reales.

- El MAE mide el promedio de las diferencias absolutas entre las predicciones ($\hat{y}_i$) y los valores reales (y_i). Siendo su fórmula:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

El MAE mide la magnitud promedio de los errores ignorando la dirección del error, es decir, no importa si la predicción es mayor o menor que el valor real. En el modelo nos indica que tan cerca o tan lejos se encuentra del valor real. [19]

- El RMSE es simplemente la raíz cuadrada del MSE. Siendo su fórmula:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

El RMSE penaliza también los errores grandes, pero es más comparable en cuanto a unidades. Es decir, si el RMSE es similar al MAE, indica que los errores son consistentes. Si el RMSE es significativamente mayor al MAE, indica que existen errores grandes que influyen al mal desempeño del modelo. [19]

El proceso del código del modelo de red neuronal se encontrará explicado en el ANEXO 10.2

5.2.10 Resultados del primer modelo (Librería h2o)

```
H2ORegressionMetrics: deeplearning
** Reported on training data. **
** Metrics reported on full training frame **

MSE: 0.6342818
RMSE: 0.7964181
MAE: 0.3885816
RMSLE: 0.2140825
Mean Residual Deviance : 0.6342818
```

Ilustración 41 Resultados Red Neuronal Modelo h2o columna V1

El modelo tiene un RMSE bajo (0.796), lo que indica que puede hacer predicciones razonablemente precisas, el MSE (0.634, bajo) indica que tiene un buen ajuste en los datos de entrenamiento. Asimismo, el MAE muestra que las predicciones están a 0.388 unidades de los valores reales.

Cada modelo obtiene su modelo de regresión, una para cada columna, con configuraciones similares. Es decir, cada modelo es independiente, los modelos no comparten información, sino que cada uno predice exclusivamente su variable objetivo. Sin embargo, tienen métricas de resultados parecidas.

```
H2ORegressionMetrics: deeplearning
** Reported on training data. **
** Metrics reported on full training frame **

MSE: 0.4502761
RMSE: 0.6710261
MAE: 0.3769485
RMSLE: NaN
Mean Residual Deviance : 0.4502761
```

Ilustración 42 Resultados Red Neuronal Modelo h2o columna V9

En la ilustración, se puede observar que, para una columna distinta, las métricas de predicción son similares y no varían bruscamente.

5.2.11 Segundo Modelo Implementado (Librería neuralnet)

El segundo modelo implementado es una red neuronal básica utilizando la librería neuralnet. Para esta red, en vez de analizar todos los datos por separado, comparando una a una. Se dividirán el conjunto de datos en dos únicas columnas, parte real y parte imaginaria, recombinándolo en un dataframe denominado `complex_data` ya que combina la parte compleja y la parte real.

Luego se aplicó una normalización, para luego entrenar la red neuronal con la librería neuralnet. Véase en la siguiente ilustración:




Ilustración 43 Plot red neuronal visualización neuralnet

Para esta red básica creada de dos capas ocultas formadas por 5 neuronas, podemos observar que tiene un Error del 8.5 que es el valor de la función de pérdida del modelo. Anteriormente explicado como el MSE. Para este caso el valor indica que está lejos de realizar buenas predicciones. Asimismo, los steps (113) indican el número de iteraciones realizadas durante el entrenamiento. Este proceso se llama Feedforward 5.2.7, para este caso el número de iteraciones es correcto pues más ajustes podría significar un sobreajuste.

Las flechas representan las conexiones entre neuronas, indicando el peso de esa conexión.

Las flechas azules son conexiones que tiene valores de peso negativo, mientras que las flechas negras corresponden a valores de peso positivos.

Los pesos positivos refuerzan la activación de las neuronas destino mientras que las negativas reducen o inhiben la activación.

El proceso del código del modelo de red neuronal se encontrará explicado en el ANEXO 10.3

5.2.12 Resultados del segundo modelo (Librería neuralnet)

Para evaluar los resultados de este modelo se utilizarán métricas obtenidas a partir de la matriz de confusión.

Una matriz de confusión nos permite la visualización del rendimiento del algoritmo. Cada fila de la matriz representa instancias en una clase predicha, mientras que cada columna representa las instancias en una clase real (o viceversa).

El nombre deriva del hecho de que hace que sea fácil ver si el sistema confunde dos clases (es decir, etiquetar erróneamente una como otra). [19]

Las clasificaciones binarias, cuando la salida puede tomar solo dos clases, nos arrojan la siguiente matriz:

Matriz de Confusión		Predicciones	
		Positivo Real	Negativo Real
Observaciones	Positivo Condicional	Verdaderos Positivos [VP]	Falsos Positivos [FP] Error tipo I
	Negativo Condicional	Falsos Negativos [FN] Error tipo II	Verdaderos Negativos [VN]

Tabla 1 Matriz de Confusión

- **Verdadero positivo [VP]:** valores predichos correctamente
- **Falsos positivos [FP]:** valores predichos incorrectamente, es decir, valores negativos predichos como positivos.
- **Falsos negativos [FN]:** valores positivos predichos como negativos
- **Verdaderos negativos [VN]:** valores predichos correctamente como negativos reales

Las métricas empleadas en el análisis de resultados son:

5.2.12.1 Exactitud (Accuracy)

$$Exactitud = \frac{VP + VN}{VP + VN + FN + FP}$$

La precisión de un modelo es la proporción de veces que el algoritmo predijo correctamente, respecto al total de datos evaluados.

5.2.12.2 Sensibilidad (Sensitivity)

$$\text{Sensibilidad} = \frac{VP}{VP + FN}$$

La sensibilidad mide la proporción de positivos reales que se identifican correctamente. Esta métrica muestra que tan bueno es el modelo para reconocer una clase positiva.

5.2.12.3 Especificidad (Specificity)

$$\text{Especificidad} = \frac{VN}{VN + FP}$$

La especificidad mide la proporción de negativos reales que se identifican correctamente.

Otras métricas relacionadas a la matriz de confusión son:

5.2.12.4 No Information Rate (NIR)

Representa la proporción de la clase mayoritaria de los datos.

$$NIR = \max(\text{Prevalencia de la clase 0}, \text{Prevalencia de la Clase 1})$$

Básicamente, indica que tan bien lo haría un clasificador que simplemente predice siempre la misma clase.

5.2.12.5 P-value

Mide si la exactitud del modelo (Accuracy) es significativamente mayor que el NIR. Es el resultado de una prueba estadística que compara hipótesis:

- Si la hipótesis es nula (H_0) el modelo no tiene mejor Accuracy que el NIR
- Si la hipótesis es alternativa (H_1) el modelo tiene mejor Accuracy que el NIR

Si el P-value es menor a 0,05 significa que es poco probable que los datos observados ocurran si la hipótesis nula fuera cierta. Por lo tanto, rechazamos la hipótesis nula y aceptamos la alternativa.

Si el P-value es mayor a 0,05 significa que los datos son consistentes con la hipótesis nula, y no la rechazamos. Aunque no necesariamente la aceptamos, solo es que no hay suficiente evidencia para rechazarla.

5.2.12.6 Kappa

Mide el grado de acuerdo entre las predicciones del modelo y las clases reales. Si el Kappa es igual o cercano al valor 1 la concordancia es perfecta o muy buena sin embargo si es muy baja o casi nula, significa que la concordancia es aleatoria. [19]

A partir de estos parámetros podemos realizar un análisis de los resultados obtenidos:

```
Confusion Matrix and Statistics

      Reference
Prediction 0  1
0      617  14
1       0   0

      Accuracy : 0.9778
      95% CI : (0.9631, 0.9878)
    No Information Rate : 0.9778
    P-Value [Acc > NIR] : 0.570441

      Kappa : 0

McNemar's Test P-Value : 0.000512

      Sensitivity : 1.0000
      Specificity : 0.0000
    Pos Pred Value : 0.9778
    Neg Pred Value :   NaN
      Prevalence : 0.9778
    Detection Rate : 0.9778
    Detection Prevalence : 1.0000
    Balanced Accuracy : 0.5000

'Positive' Class : 0
```

Ilustración 44 Primer resultado modelo neuralnet

Para el primer modelo se obtuvo los resultados de la ilustración, los cuales indican que este modelo no está aprendiendo correctamente la clase 1, debido a que predice constantemente la clase 0 y no la 1, asimismo también se puede ver igual de claro ya que el Kappa y la especificidad son muy bajas. Donde el resultado del Balanced Accuracy da como resultado 50%, sugiere que el modelo no está bien equilibrado.

Para mejorar el modelo se realizó un submuestreo (oversampling) aumentar la cantidad de datos de la clase minoritaria, con la librería ROSE.

```
Confusion Matrix and Statistics

      Reference
Prediction 0  1
0      311  310
1       1    9

      Accuracy : 0.5071
      95% CI : (0.4674, 0.5468)
    No Information Rate : 0.5055
    P-Value [Acc > NIR] : 0.4842

      Kappa : 0.0247

McNemar's Test P-Value : <2e-16

      Sensitivity : 0.99679
      Specificity : 0.02821
    Pos Pred Value : 0.50081
    Neg Pred Value : 0.90000
      Prevalence : 0.49445
    Detection Rate : 0.49287
    Detection Prevalence : 0.98415
    Balanced Accuracy : 0.51250

'Positive' Class : 0
```

Ilustración 45 Segundo resultado modelo neuralnet

Este otro modelo tiene un sesgo hacia la clase 0, por lo que favorece a la clase mayoritaria en los datos balanceados, para este caso cambiaremos la cantidad de capas o neuronas propiamente descritas anteriormente para mejorar la arquitectura de la red, otra posible solución es experimentar con otros tipos de modelos como Árboles de decisión o Maquinas de soporte Vectorial. Sin embargo, el objetivo de este proyecto es utilizar RRNN, por lo que no se utilizaran. Asimismo, también se hará otro submuestreo, pero siendo un (undersampling), es decir reduciendo la clase mayoritaria.

```
Confusion Matrix and Statistics

      Reference
Prediction 0  1
0  174  62
1   34 202

      Accuracy : 0.7966
      95% CI : (0.7574, 0.832)
      No Information Rate : 0.5593
      P-Value [Acc > NIR] : < 0.00000000000000022

      Kappa : 0.5932

      Mcnemar's Test P-Value : 0.005857

      Sensitivity : 0.8365
      Specificity : 0.7652
      Pos Pred Value : 0.7373
      Neg Pred Value : 0.8559
      Prevalence : 0.4407
      Detection Rate : 0.3686
      Detection Prevalence : 0.5000
      Balanced Accuracy : 0.8008

      'Positive' Class : 0
```

Ilustración 46 Tercer resultado modelo neuralnet

Para este modelo el accuracy o la precisión es razonablemente buena ya que clasifica el modelo correctamente alrededor de un 80% y tiene un valor Kappa razonable (0,5932), lo cual indica un moderado acuerdo entre predicciones y valores reales, mucho mejor con respecto al modelo anterior. Sin embargo, todavía comete algunos errores en ambas direcciones, lo cual es normal en la mayoría de los modelos. Asimismo, la sensibilidad es ligeramente mejor que la especificidad, lo que indica que el modelo le es más fácil identificar correctamente la clase 0 que la clase 1.

5.3 Recursos requeridos

Software:

- ITK-Snap
- Matlab
- Rstudio

César Carrasco Pérez

Equipo técnico:

- Ordenador ASUS VivoBook Intel Core I7

Estudios e informes:

- Artículos e informes para la documentación del proyecto

Otros recursos:

- Imágenes de Resonancia Magnéticas
- Base de datos de señales reales de Resonancia Magnética

5.4 Presupuesto

Tipo de coste	Valor	Comentarios
Horas de trabajo en el proyecto	420 horas* 20€ sueldo medio ingeniero biomédico junior = 8.400€	
Equipo técnico utilizado	Ordenador ASUS VivoBook 16 Intel Core I7 = 899€	En este caso, no ha sido necesario adquirir el equipo, pues ya se disponía de el.
Software utilizado	Licencia de estudiante de Matlab 28.500USD = 26.655€	El valor adjudicado para las licencias de Matlab y Rstudio es el indicado, pero al ser estudiante de la Universidad Europea, la universidad nos da disponibilidad de ellas de forma gratuita.
	Software ITK-Snap: gratuita	
	Software de Rstudio: al año 995USD = 929,13€	
	TOTAL: 0€	
Estudios e informes	Artículos, informes y revistas: 0€	El coste de los artículos utilizados, revistas e información ha sido gratis.

Materiales empleados	Imágenes de Resonancia Magnéticas 450€ por cada Imagen	En España el precio promedio de una resonancia oscila entre los 300 y 600€. Sin embargo, para el proyecto ha sido recibido gratuitamente La base de datos de señales reales ha sido recibida gratuitamente
	Base de datos de señales reales de Resonancia Magnética: 0€	
TOTAL	Precio sin ser estudiante: 46. 183,13€	El precio siendo estudiante sin tener en cuenta el equipamiento técnico es de 8.400€
	Precio siendo estudiante: 9.299€	

Tabla 2 Tabla Presupuesto

5.5 Viabilidad

El proyecto es técnicamente viable, gracias a las herramientas de software disponibles y la precisión de los datos obtenidos. Económicamente, el bajo costo relativo del modelo propuesto lo convierte en una alternativa atractiva para instituciones médicas. Sin embargo, su éxito dependerá de la capacidad de abordar riesgos como la disponibilidad de datos y complejidad de los modelos, para lo cual se plantea un enfoque iterativo que permita ajustar y mejorar continuamente las redes neuronales.

Este proyecto tiene un potencial económico significativo debido a que produce una reducción de costos en el diagnóstico y tratamiento para las enfermedades relacionadas con el Sistema Nervioso. Además, se podría implementar en futuros dispositivos médicos o software de diagnóstico que podrían tener un valor comercial significativo.

Desde un punto de vista sobre un análisis sostenible, el proyecto tiene potencial de hacer importantes contribuciones al campo de la neurociencia computacional y la medicina, así como mejorar la calidad de vida de las personas.

Algunos riesgos que pueden influir al proyecto son:

- La disponibilidad de datos: La cantidad de los datos determinará la calidad de los modelos de redes.
- Complejidad de los modelos: Es importante desarrollar modelos bien entrenados, cuanto más complejos sean, mejores resultados se obtendrán

- Interpretación de resultados: puede llegar a ser difícil interpretar los resultados de los modelos de las redes neuronales, para ello es importante desarrollar métodos para explicar los resultados y comprender su relación con los datos reales

En definitiva, el proyecto tiene potencial y es viable desde el punto de vista técnico, económico y sostenible, sin embargo, el éxito dependerá de la capacidad de abordar los riesgos mencionados de manera efectiva.

5.6 Resultados del proyecto

En recapitulación en base a los resultados obtenidos, el proyecto ha logrado alcanzar los objetivos planteados

En primer lugar, se logró realizar una segmentación precisa del LCR a partir de imágenes reales de MRI mediante el software de ITK-Snap. Este proceso incluyó ajustes manuales y automáticos de contrastes, presegmentaciones utilizando el método Thresholding y posteriormente una segmentación manual en las áreas que presentaban irregularidades. Donde finalmente, se obtuvieron el volumen para cada segmentación.

Luego se consiguió calcular el volumen del LCR segmentado (a través de Matlab) y no se pudo estimar los parámetros de velocidad del flujo a partir de la derivada temporal del volumen. Debido a que las imágenes del MRI no eran temporales. No obstante, se recurrió a modelos computacionales de dinámica de fluidos para simular patrones de flujo, logrando resultados coherentes con los datos fisiológicos esperados en un paciente sano.

Seguidamente a través del modelo se obtuvo un análisis de Fourier que permitió descomponer los datos del flujo en componentes sinusoidales, pudiendo identificar las variaciones según la región anatómica. En la que se pudo contemplar una disminución progresiva en la amplitud del flujo conforme el líquido desciende hacia la región lumbar, impulsado por el PIC. Reflejando así la influencia de factores como la resistencia, geometría y elasticidad del canal. Asimismo, se simuló casos con parámetros fisiológicos anormales, pudiendo demostrar como algunas alteraciones afectan a la dinámica del flujo del LCR. Por ejemplo, bajos niveles de elasticidad y resistencia resultaron en oscilaciones más prolongadas, mientras que valores más altos generaron flujos iniciales más intensos con amortiguaciones más rápidas. Pudiendo identificar aquellos modelos que podrían utilizarse para identificar patrones asociados a posibles afecciones.

Por último, se consiguió implementar dos modelos de redes neuronales mediante el uso de Rstudio, empleando los datos obtenidos en los análisis previos. Dichas RRNN se entrenaron y consiguieron datos satisfactorios.

- Modelo h2o: Obtuvo un MSE bajo lo que indica un ajuste adecuado en las predicciones de los valores reales.
- Modelo neuralnet: Se consiguió unos datos de sensibilidad, especificidad y exactitud aceptables para confirmar la validez del modelo como herramienta predictiva.

En resumen, las herramientas y metodologías utilizadas en este proyecto permitieron abordar efectivamente los objetivos planteados, desde la segmentación precisa de imágenes de resonancia magnética hasta el diseño y validación de redes neuronales capaces de modelar patrones complejos para mejorar el diagnóstico médico de enfermedades relacionadas con el sistema nervioso central.

Capítulo 6. DISCUSIÓN

6.1 Discusión Interpretativa de los resultados

Los resultados obtenidos confirman la viabilidad de utilizar herramientas computacionales para estudiar la dinámica del LCR. La segmentación de imágenes de MRI permitió extraer datos de volumen y simular flujos oscilatorios, mostrando patrones consistentes con la fisiología esperada. Además, la implementación de Redes Neuronales Artificiales (RRNN) para modelar el comportamiento del LCR produjo resultados prometedores, destacando especialmente el modelo basado en la librería h2o, que presentó métricas bajas de error (RMSE:0.796; MSE:0.634).

Las simulaciones con parámetros alterados, como elasticidad y resistencia, ofrecieron información relevante sobre su influencia en el flujo del LCR. Por ejemplo, en enfermedades anteriormente mencionadas como el Alzheimer, alteraciones en la dinámica del LCR, como una disminución en la amplitud de la oscilación o una menor frecuencia en los ciclos de flujo, podría llegar a relacionarse con un sistema de eliminación de desechos menos eficientes.

Estos hallazgos sugieren un potencial uso clínico para identificar anomalías tempranas en patologías relacionadas con el LCR, como, trastornos neurodegenerativos o hidrocefalias. Además, validan la metodología planteada, subrayando el potencial de las herramientas de inteligencia artificial como complemento al diagnóstico médico. Sin embargo, se reconoce la necesidad de ampliar el conjunto de datos y utilizar imágenes temporales para mejorar la representatividad de los resultados.

6.2 Discusión autodescriptiva del proyecto

El proyecto presentó diversas complicaciones durante el transcurso, limitaciones inherentes a la tecnología utilizada como también la metodología aplicada.

- Las imágenes de Resonancia Magnética

En un principio se tenía pensado utilizar imágenes de MRI temporales, para cuando se realizase la segmentación, obtener el volumen del LCR a través de su derivada. Sin embargo, durante los primeros meses de desarrollo del proyecto, los archivos de la MRI temporal no se configuraban en el software de ITK-Snap, para ello se intentó de diversas maneras conseguir solucionar el problema sin éxito. Por lo que, frente a un problema de una circunstancia incapaz de solucionar, se optó por adaptar el proyecto, se recurrió a imágenes de MRI espaciales y luego utilizar un modelo computacional que simularía el flujo oscilatorio. Aunque este cambio permitió continuar con el proyecto, los resultados no son completamente representativos de datos reales al detalle.

- Complejidad del Modelo de Red Neuronal

Aunque los modelos empleados mostraron resultados aceptables, no se implementó una red neuronal de gran profundidad debido a las restricciones de recursos computacionales y tiempo. Esto podría limitar la capacidad del modelo para capturar patrones más complejos. Para ello se

decidió priorizar la simplicidad en los modelos de las redes neuronales para cumplir con las limitaciones que se tenían.

- Datos Limitados

El proyecto utilizó un conjunto de datos reducido, lo que puede afectar a la generalización del modelo a otros casos clínicos con condiciones anatómicas más específicas. Para ello aumentar el conjunto de datos podría mejorar el entrenamiento de nuestra red y por lo tanto los resultados obtenidos.

Capítulo 7. CONCLUSIONES

7.1 Conclusiones del trabajo

El objetivo del proyecto consistió en estudiar el movimiento del líquido cefalorraquídeo mediante la segmentación de imágenes de resonancia magnética y la implementación de un modelo de red neuronal capaz de analizar y predecir patrones relacionados con el flujo. Los resultados obtenidos muestran que las herramientas empleadas, como ITK-Snap para la segmentación y las redes realizadas en Rstudio, han sido eficaces para procesar datos y generar modelos con capacidad predictiva. Adicionalmente, se logró simular alteraciones en parámetros fisiológicos como la elasticidad o la resistencia, lo que permite asociar patrones de flujo con posibles patologías neurológicas.

Este proyecto cumple satisfactoriamente la metodología utilizada como método no invasivo basado en inteligencia artificial al estudio del LCR, aportando una alternativa prometedora frente a técnicas convencionales de diagnóstico.

7.2 Conclusiones personales

Este proyecto ha significado un reto desafiante, pues he tenido que adaptarme a cambios durante el desarrollo y superar limitaciones técnicas. Durante el transcurso del desarrollo he aprendido a integrar los conocimientos teóricos y prácticos que he adquirido en el grado, en áreas como el procesamiento de imágenes, inteligencia artificial y estructuras anatómicas relacionadas en el ámbito de la medicina entre otras. Este proyecto me ha permitido apreciar la importancia de la colaboración interdisciplinar, entre los ingenieros y profesionales de la salud, para abordar problemas complejos con soluciones innovadoras.

El estudio del LCR y su relación con diversas patologías tiene una relevancia significativa en el ámbito médico, y haber contribuido, aunque sea de forma inicial, al desarrollo de nuevas herramientas para su análisis es algo que me llena profundamente. Además, considero que este trabajo tiene una base sólida para futuras investigaciones.

Capítulo 8. FUTURAS LÍNEAS DE TRABAJO

Para ampliar y mejorar el proyecto en un futuro en basándose en lo ya realizado, existen varias maneras de tratar un proyecto futuro. Considerando las restricciones del proyecto, un buen punto a tener en cuenta para líneas futuras es la integración de imágenes temporales de MRI. Como se ha mencionado con anterioridad, incorporar imágenes dinámicas con registro temporal permitiría calcular directamente el flujo oscilatorio del LCR y validar de forma más precisa los modelos. Asimismo, ampliar el conjunto de datos del modelo, ayudaría a mejorar la precisión de estas, pudiendo entrenar con un conjunto de datos más grandes e identificar patrones más complejos. En cuanto a los modelos, también se podrían desarrollar redes neuronales mucho más complejas, como, mayor número de capas ocultas y recursos computacionales más avanzados.

Otras líneas futuras para el proyecto sin relación a las limitaciones podrían ser una posible validación clínica de los modelos, es decir, colaborar con profesionales médicos para validar los modelos desarrollados en entornos clínicos reales, y poder tener una utilidad en la práctica médica.

Una optimización del proceso de segmentación, aunque la segmentación manual fue útil para mejorar la precisión, la automatización completa mediante algoritmos más avanzados podría reducir el tiempo y errores asociados al procesamiento de imágenes. La segmentación manual es una solución puntual, pero no escalable, por ello el uso de redes neuronales convolucionales, sería una mejora significativa para automatizar el proceso.

Finalmente, una línea futura podría centrarse en desarrollar una aplicación médica basada en inteligencia artificial que integre los modelos predictivos y permita los profesionales de la salud realizar diagnósticos preliminares de manera no invasiva y rápida.

Capítulo 9. REFERENCIAS

- [1] M. J. De la Torre Guitiérrez, «Sistema Nervioso». Equipo de La Torre, 8 de agosto de 2023. [En línea]. Disponible en: <https://www.neurocirugiaequipodelatorre.es/que-es-y-como-se-estructura-el-sistema-nervioso#:~:text=Se%20llama%20sistema%20nervioso%20al,gran%20red%20de%20terminaciones%20nerviosas.>
- [2] J. Vélez, «Sistema Nervioso», Kenhub. [En línea]. Disponible en: <https://www.kenhub.com/es/library/anatomia-es/sistema-nervioso>
- [3] S. G. Waxman, «Neuroanatomía clínica».
- [4] M. I. Escobar y H. J. Pimienta, «Sistema nervioso», *Sist. Nerv.*, 2020, doi: 10.2307/j.ctv14jx7cw.
- [5] F. H. Netter, «ATLAS DE ANATOMÍA HUMANA».
- [6] T. O. Wichmann, H. H. Damkier, y M. Pedersen, «A Brief Overview of the Cerebrospinal Fluid System and Its Implications for Brain and Spinal Cord Diseases», *Front. Hum. Neurosci.*, vol. 15, n.º January, pp. 1-7, 2022, doi: 10.3389/fnhum.2021.737217.
- [7] F. Arikan, «Anatomía y fisiología del sistema nervioso central».
- [8] A. C. Aguirre-espinosa, «Dinámica del líquido cefalorraquídeo y barrera hematoencefálica», vol. 20, n.º 1, pp. 60-64, 2015.
- [9] M. Carolina Galofre-Martínez, D. Puello-Martínez, A. Arévalo-Sarmiento, Y. Ramos-Villegas, L. Quintana-Pájaro, y L. Rafael Moscote-Salazar, «Revisión de Tema Doctrina Monro-Kellie: fisiología y fisiopatología aplicada para el manejo neurocrítico Monro-Kellie doctrine: physiology and pathophysiology applied for neurocritical management», *Rev. Chil. Neurocir.*, vol. 45, pp. 169-174, 2019.
- [10] V. Haughton y K. A. Mardal, «Spinal fluid biomechanics and imaging: An update for neuroradiologists», *Am. J. Neuroradiol.*, vol. 35, n.º 10, pp. 1864-1869, 2014, doi: 10.3174/ajnr.A4023.
- [11] R. Magn, «Técnicas de Imagen Biomedica», 2023.
- [12] E. G. Martín, M. R. Cancio, L. P. Triana, y E. G. Cabrera, «Detección del volumen del líquido Cefalorraquídeo a través de imágenes de Resonancia Magnética Cerebrospinal fluid volume detection through Magnetic Resonance Imaging», vol. 10, pp. 133-144, 2016.
- [13] F. Pacchiano *et al.*, «Artificial intelligence applied in acute ischemic stroke: from child to elderly», *Radiol. Med. (Torino)*, vol. 129, n.º 1, pp. 83-92, 2024, doi: 10.1007/s11547-023-01735-1.
- [14] S. T. van Hal, M. van der Jagt, M. E. van Genderen, D. Gommers, y J. F. Veenland, «Using Artificial Intelligence to Predict Intracranial Hypertension in Patients After Traumatic Brain Injury: A Systematic Review», *Neurocrit. Care*, vol. 41, n.º 1, pp. 285-296, 2024, doi: 10.1007/s12028-023-01910-2.

- [15] G. R. E. Bradley, M. Roldán, y P. A. Kyriacou, «Machine Learning Approaches to Intracranial Pressure Prediction in Patients with Traumatic Brain Injury: A Systematic Review», *Appl. Sci. Switz.*, vol. 13, n.º 14, 2023, doi: 10.3390/app13148015.
- [16] S. W. Bothwell, D. Janigro, y A. Patabendige, «Cerebrospinal fluid dynamics and intracranial pressure elevation in neurological diseases», *Fluids Barriers CNS*, vol. 16, n.º 1, pp. 1-18, 2019, doi: 10.1186/s12987-019-0129-6.
- [17] T. R. Neuronales, T. R. Neuronales, y P. Larra, «Tema 8. Redes Neuronales», n.º July, 2015.
- [18] INGERNIEROS, «Algoritmos de aprendizaje automático», *Microsoft*, 2020.
- [19] G. James, D. Witten, T. Hastie, y R. Tibshirani, *An introduction to Statistical Learning*, vol. 7, n.º 10. 2000. doi: 10.1007/978-1-4614-7138-7.

Capítulo 10. ANEXOS

10.1 Código Implementación Matlab

```
% Iteramos sobre cada corte en el eje Z
for z = 1:dimZ
    % Obtenemos el corte en cada eje Z
    slice = Z(:, :, z);

    % Obtenemos el perímetro de la región en el corte
    perimetro = bwperim(slice);

    % Rellenamos el área dentro del perímetro
    rellenar = imfill(perimetro, 'holes');

    % Calculamos el área (píxeles) dentro del perímetro relleno
    area = sum(perimetro(:));

    % Sumamos el área al volumen total en voxeles
    volumenVoxels = volumenVoxels + area;
end

% Calculamos el volumen de cada voxel en unidades físicas
volumenPorVoxel = voxelX * voxelY * voxelZ;

% Ajustamos el volumen total a unidades físicas
volumen = volumenVoxels * volumenPorVoxel;

disp(['El volumen de la imagen 3D es aproximadamente ', ...
    num2str(volumen), ' mm3.']);
```


10.2 Código Modelo red neuronal h2o

```
library(h2o)

# Iniciamos el entorno de h2o, además le decimos que pueda usar mas G de nuestro
#ordenador, para un proceso computacional más rápido
h2o.init(max_mem_size = "8G")

# Cargamos los datos
# Convertir los dataframes a h2o frames

h2o_train <- as.h2o(q_out) # train_data contiene Elasticidad, Resistencia y 420 columnas
h2o_test <- as.h2o(params_in) # test_data tiene la misma estructura, pero con las 22 columnas de salida

# columnas_inputs: nombres de las 420 columnas de entrada
# columnas_outputs: nombres de las 22 columnas de salida

# Definimos los nombres de las columnas de entrada (420 columnas)
columnas_inputs <- colnames(h2o_train)[1:420]

# Definimos los nombres de las columnas de salida (22 columnas)
columnas_outputs <- colnames(h2o_test)[1:22]

# Creamos una lista para almacenar los modelos
modelos_outputs <- list()

# Entrenamos un modelo para cada columna de salida
for (col in columnas_outputs) {
  cat("Entrenando modelo para la columna de salida:", col, "\n")
  modelos_outputs[[col]] <- h2o.deeplearning(
    x = columnas_inputs, # Variables independientes (420 columnas)
    y = col, # Una única variable de salida
    training_frame = h2o_train, # Datos de entrenamiento
    activation = "RectifierwithDropout", # Función de activación
    hidden = c(15, 15), # Número de neuronas en cada capa oculta
    epochs = 100, # Número de epochs
    stopping_metric = "RMSE", # Métrica de parada
    seed = 123, # Fijar semilla para reproducibilidad
    balance_classes = FALSE, # No balancear clases
    standardize = TRUE # Normalizar automáticamente
  )
}

# Mostramos los modelos entrenados
cat("\nModelos entrenados:\n")
print(names(modelos_outputs))

summary(modelos_outputs$V9)
summary(modelos_outputs)
# Finalizar h2o
h2o.shutdown(prompt = FALSE)
```

10.3 Código Modelo red neuronal neuralnet

```
#Librerías
library(neuralnet)
library(caret)
library(ROSE)

#-----Red-----
Q_out2<- Q_out
params_in2<- params_in
# Modificamos el nombre de las primeras dos columnas
colnames(Q_out2)[1]<- "G" # Elasticidad
colnames(Q_out2)[2]<- "R" # Resistencia

Q_out2 <- Q_out2[-2101,] |
params_in2 <- params_in2[-2101,]

# Dividir en parte real e imaginaria
real_values <- Q_out2$V3[seq(1, nrow(Q_out2), by = 2)]
imag_values <- Q_out2$V4[seq(2, nrow(Q_out2), by = 2)]

# Dividir en parte real e imaginaria
real_values2 <- params_in2$V3[seq(1, nrow(params_in2), by = 2)]
imag_values2 <- params_in2$V4[seq(2, nrow(params_in2), by = 2)]

str(real_values)
str(imag_values)
str(real_values2)
str(imag_values2)

# Creamos un dataframe con la parte real e imaginaria para Q_out
complex_data <- data.frame(real = real_values, imag = imag_values)

# Creamos un dataframe con la parte real e imaginaria para params_in
complex_data2 <- data.frame(real = real_values2, imag = imag_values2)

# Normalizar los datos
normalizar <- function(x) {
  return ((x - min(x)) / (max(x) - min(x)))
}

# Aplicar normalización
complex_data$real <- normalizar(complex_data$real)
complex_data$imag <- normalizar(complex_data$imag)

# Aplicar normalización
complex_data2$real <- normalizar(complex_data2$real)
complex_data2$imag <- normalizar(complex_data2$imag)

# Dividimos los datos en entrenamiento (70%) y prueba (30%)
set.seed(123)
train_index <- sample(1:nrow(complex_data), 0.7 * nrow(complex_data))
train_data <- complex_data[train_index, ]
test_data <- complex_data[-train_index, ]

# Definimos el modelo de la red neuronal
nn_model <- neuralnet(real ~ imag, data = train_data, hidden = c(5,5), linear.output = TRUE)

# Resultados del modelo
plot(nn_model)
```

```
# Realizamos predicciones
predicciones <- compute(nn_model, complex_data2$imag)
# Convertimos la parte imaginaria de los datos de prueba a un dataframe
imag_test_data <- data.frame(imag = complex_data2$imag)
# Realizamos predicciones
predicciones <- neuralnet::compute(nn_model, imag_test_data)

# Predicciones
predicted_values <- predicciones$net.result
predicciones$net.result

# Ajustar el tamaño de predicted_values para que coincida con test_data
predicted_values <- predicted_values[1:nrow(test_data)]

# Comparar los valores predichos con los reales
comparar <- data.frame(actual = test_data$real, predicted = predicted_values)
print(comparar)

# Clasificar predicciones

# Definimos un umbral para convertir las predicciones continuas en clases
umbral <- 0.5
predicted_class <- ifelse(predicted_values > umbral, 1, 0) # Convertimos a clases 0 y 1
clase_real <- ifelse(real_test > umbral, 1, 0) # Convertimos valores reales a clases 0 y 1

# Creamos la matriz de confusión
conf_matrix <- table(Predicted = predicted_class, Actual = clase_real)
print(conf_matrix)

# Convertimos las clases predichas y reales a factores con los mismos niveles
predicted_class <- factor(predicted_class, levels = c(0, 1))
clase_real <- factor(clase_real, levels = c(0, 1))

# Creamos la matriz de confusión con la librería caret
confusionMatrix(as.factor(predicted_class), as.factor(clase_real))
print(confusionMatrix())

# Sobremuestreo de la clase minoritaria (clase 1) o submuestreo de la clase mayoritaria (clase 0)
datos_balanced <- ovun.sample(real ~ imag, data = complex_data, method = "both", p = 0.5, seed = 123)$data

# Verificamos el número de observaciones en cada clase después del balanceo
table(datos_balanced$real)

# Dividir los datos balanceados en entrenamiento (70%) y prueba (30%)
set.seed(123)
train_index <- sample(1:nrow(datos_balanced), 0.7 * nrow(datos_balanced))
train_data <- datos_balanced[train_index, ]
test_data <- datos_balanced[-train_index, ]

# Entrenamos el modelo de red neuronal con los datos balanceados
nn_model <- neuralnet(real ~ imag, data = train_data, hidden = 5, linear.output = FALSE)
```

[PÁGINA INTENCIONADAMENTE EN BLANCO]