



Benemérita Universidad Autónoma de Puebla

---

Facultad de Ciencias Físico Matemáticas

---

Aplicación de Redes Neuronales en el análisis de imágenes  
de Resonancia Magnética de cuerpo completo en pacientes  
infantiles.

Tesis presentada al

**Colegio de Física**

como requisito parcial para la obtención del grado de

**LICENCIADO EN FÍSICA APLICADA**

por

Mireya Estefany Márquez López

Asesorada por

Dr. Benito De Celis Alonso y Dr. Javier M. Hernández

Puebla Pue.  
14 de octubre de 2022





Benemérita Universidad Autónoma de Puebla

---

Facultad de Ciencias Físico Matemáticas

---

Aplicación de Redes Neuronales en el análisis de imágenes de Resonancia Magnética de cuerpo completo en pacientes infantiles.

Tesis presentada al

**Colegio de Física**

como requisito parcial para la obtención del grado de

**LICENCIADO EN FÍSICA APLICADA**

por

Mireya Estefany Márquez López

Asesorada por

Dr. Benito De Celis Alonso y Dr. Javier M. Hernández

Puebla Pue.  
14 de octubre de 2022



**Título:** Aplicación de Redes Neuronales en el análisis de imágenes de Resonancia Magnética de cuerpo completo en pacientes infantiles.

**Estudiante:** MIREYA ESTEFANY MÁRQUEZ LÓPEZ

COMITÉ

---

Dr. Eduardo Moreno Barbosa  
Presidente

---

Dr. Cristian Heber Zepeda Fernández  
Secretario

---

Dr. Lucio Fidel Rebolledo Herrera  
Vocal

---

Vocal

---

Dr. Benito De Celis Alonso y Dr. Javier M. Hernández  
Asesor

# Índice general

<b>1. Introducción</b>	<b>3</b>
1.1. Presentación del problema . . . . .	3
1.2. Hipótesis . . . . .	4
1.3. Objetivos primarios y secundarios del trabajo . . . . .	4
1.4. Resumen sobre estructura de la tesis . . . . .	4
1.5. Índice de abreviaturas . . . . .	6
<b>2. Fundamento Teórico</b>	<b>7</b>
2.1. Obesidad y problemas de salud asociados . . . . .	7
2.1.1. Clasificación . . . . .	7
2.1.2. Causas de la obesidad . . . . .	8
2.1.3. Problemas de salud asociados. . . . .	8
2.2. Hígado graso y patologías asociadas con la obesidad . . . . .	10
2.2.1. Patología de hígado graso no-alcohólico asociada a obesidad . . . . .	10
2.3. Resonancia magnética general . . . . .	12
2.3.1. Producción de magnetización neta . . . . .	12
2.3.2. Conceptos de Resonancia Magnética . . . . .	17
2.3.3. Tiempos de relajación: $T_1$ y $T_2$ . . . . .	17
2.3.4. Imagen de resonancia magnética . . . . .	19
2.4. Inteligencia Artificial en general . . . . .	24
2.4.1. Antecedentes de la Inteligencia Artificial . . . . .	26
2.4.2. Ramas que componen la Inteligencia Artificial . . . . .	26
2.5. Algoritmos KNN y Naive Bayes, Redes Neuronales . . . . .	30
2.5.1. k-Nearest Neighbour . . . . .	30
2.6. Aplicaciones de redes neuronales a imágenes médicas de obesidad . . . . .	38
<b>3. Métodos</b>	<b>43</b>
3.1. Descripción de la población a estudiar. . . . .	43
3.2. Hardware usado para estudio. . . . .	44
3.3. Software usado para estudio. . . . .	44
3.3.1. Python . . . . .	44
3.3.2. TensorFlow . . . . .	44
3.3.3. Keras . . . . .	45
3.4. Diseño o Estructura de nuestra Red Neuronal. . . . .	46
3.5. Estadística. . . . .	53
3.5.1. Aspectos básicos . . . . .	53
3.5.2. Precisión . . . . .	54
<b>4. Resultados</b>	<b>57</b>
<b>5. Discusión y Conclusiones</b>	<b>63</b>

x

*ÍNDICE GENERAL*

**A. Código de la Red Neuronal**

**71**

**B. DICOM®**

**73**

**Bibliografía**

**75**

# Resumen

En este proyecto de tesis se pretende estudiar, usando redes neuronales, biomarcadores en imágenes de resonancia magnética de niños con obesidad y niños saludables (en su peso adecuado). En particular nos interesa crear una red que distinga los dos grupos basados en la concentración de grasa en cuerpo entero.

Para lograr esto se hace uso de una Red Neuronal Convolutiva. El análisis de las imágenes de resonancia magnética se divide en dos partes, la primera consiste en cambiar el formato de las imágenes DICOM a .jpg, esto con el fin de poder usarlas como entradas de la red. En la segunda, las imágenes con su nuevo formato, entrarán a la Red Neuronal Convolutiva pasarán por filtros (detectores de rasgos), con el propósito de obtener mapas de características, los cuales posteriormente pasarán por una capa de agrupación con el objetivo de que la red sea capaz de detectar una imagen independientemente de las variantes que pueda haber en ella (rotación, escalado). Una vez hecho lo anterior los resultados serán aplanados en un vector unidimensional, que será la capa de entrada de la Red Neuronal totalmente conectada, en esta parte comienza el entrenamiento de la Red Neuronal, se asignan pesos pequeños aleatoriamente, estos eran ajustados con el método de backpropagation.

**Palabras clave :** Redes neuronales, redes neuronales convolucionales, imágenes de resonancia magnética, backpropagation.



# Capítulo 1

## Introducción

### 1.1. Presentación del problema

La obesidad es una enfermedad crónica multifactorial en la que están involucrados aspectos genéticos, ambientales y de estilo de vida, que condicionan una acumulación excesiva de grasa corporal. Los principales factores de riesgo identificados son la inactividad física, el sedentarismo, la ingesta de alimentos con alta densidad energética y en grandes porciones, el consumo de refrescos y bebidas azucaradas, y una frecuente ingesta de alimentos entre comidas.

La prevalencia de obesidad ha incrementado a nivel mundial en las últimas tres décadas, y afectó a uno de cada tres adultos en 2014 [8] [9]. A pesar de que la velocidad de incremento en la prevalencia de obesidad en los adultos mexicanos disminuyó en el periodo de 2000 a 2016, [10] la tendencia mantenida ha provocado que, actualmente, México sea uno de los dos países con mayor prevalencia de obesidad en el mundo. [11]

México es uno de los cinco países de Latinoamérica con la prevalencia más alta de sobrepeso (9.0 %) en niños menores de cinco años, junto con Argentina (9.9 %), Paraguay (11.7 %), Barbados (12.2 %) y Belice (13.7 %). En el caso de los niños mayores de cinco años, México es el país con la prevalencia más alta de sobrepeso (43.9 %) en Latinoamérica. [12]

En los menores de cinco años, las prevalencias combinadas de riesgo de sobrepeso más obesidad (SP+O) aumentó de 26.6 a 33.6 % entre los años 1988 y 2012. En el grupo de edad escolar, las prevalencias de SP+O incrementaron de 28.2 a 36.9 % en niños y de 25.5 a 32 % en niñas en el periodo de 1999 a 2012.

Existe una estrecha relación entre el hígado graso en los niños y la obesidad infantil. El hígado graso es la acumulación excesiva de grasa (triglicéridos) en el hígado, la cual puede llevar a un mal funcionamiento y un grado variable de afectación de este órgano, que va desde la simple acumulación de grasa en el hígado sin síntomas asociados, pasando por la fibrosis hasta llegar la cirrosis.

La obesidad se asocia a numerosas complicaciones. En la frecuencia e intensidad de las mismas parece influir el depósito de grasa intraabdominal.

La resonancia magnética es una técnica con una gran resolución espacial y capacidad de discriminación tisular. La resonancia magnética de cuerpo completo se ha usado para el estudio de la cuantificación de grasa en pacientes pediátricos con miopatías hereditarias con el fin de complementar el estudio genético e histopatológico [5].

Al tener imágenes de resonancia magnética, contar con ayuda informática facilita los procesos de diagnóstico, ya que los computadores lo hacen de manera sistemática y exhaustiva, no dependiente de la experiencia o del estado actual del clínico, además que elimina la necesidad de una memoria operacional que sobrepasa la capacidad humana [70].

## 1.2. Hipótesis

La aplicación de la Inteligencia Artificial, como lo es el uso de las Redes Neuronales para la clasificación de imágenes médicas puede ayudar a detectar anomalías en éstas.

## 1.3. Objetivos primarios y secundarios del trabajo

El principal objetivo del presente trabajo es crear una red neuronal capaz de distinguir el grupo de imágenes de niños con obesidad del grupo de normopeso, basandose en la concentración de grasa en cuerpo entero.

### Objetivos secundarios

- Hacer uso de la Red Neuronal Convolutiva en otro tipo de imágenes médicas, para el diagnóstico solicitado.
- Automatización del algoritmo que permite el cambio de un formato a otro.
- Comprensión del funcionamiento de una Red neuronal convolutiva.
- Repaso del estado de arte de redes neuronales en biomarcadores en imágenes médicas.
- Estado del arte de análisis de imagen médica en general.

## 1.4. Resumen sobre estructura de la tesis

El capítulo 2 del presente expone los fundamentos teóricos necesarios para un entendimiento óptimo del trabajo. En el primer apartado se habla sobre la obesidad y problemas de salud asociados, con el fin de reafirmar y conocer un poco más el problema de la obesidad. El siguiente apartado habla sobre la enfermedad hepática por depósito de grasa y las patologías asociadas con la obesidad. Además, se expone la Resonancia Magnética en general explicando los aspectos más importantes detrás de ésta, como la Imagen de Resonancia Magnética, ya que los recursos usados en la Red son Imágenes de Resonancia Magnética. En los siguientes apartados se habla sobre la Inteligencia Artificial en general, cubriendo sus antecedentes y las ramas que la componen. Se mencionan los algoritmos k-Nearest Neighbour, Naive Bayes y Redes Neuronales con el fin de conocer y comprender los aspectos más importantes de estos. El apartado de Redes Neuronales es más extenso en comparación con los de los algoritmos restantes, expone la historia de las Redes Neuronales, los componentes más importantes, las funciones de activación, el entrenamiento de éstas, el perceptrón, redes multicapa y el descenso del gradiente, así como también se exponen las Redes Neuronales de Convulsión. El último apartado de este capítulo muestra las aplicaciones que se le han dado a las Redes Neuronales en las análisis de imágenes médicas en general, con la presentación de algunos artículos.

En el capítulo 3 se exponen los métodos utilizados, tales como la descripción de la población a estudiar. Se habla del hardware, detalles de el aparato de resonancia magnética y de la computadora usada para el desarrollo de la red, también se expone el software utilizado para

**CAPÍTULO 1. INTRODUCCIÓN**  
**1.4. RESUMEN SOBRE ESTRUCTURA DE LA TESIS**

---

hacer el estudio, exponiendo las librerías utilizadas. Se presenta el diseño y la estructura de la Red Neuronal, explicando cada uno de los elementos que la conforman y aclarando el uso de cada uno de ellos. Por último se habla sobre la estadística de nuestra Red.

En las siguientes capítulos se exponen los resultados obtenidos una vez que la red ha sido entrenada, aclarando la obtención de cada uno de ellos. Se expone la discusión de los resultados obtenidos y las conclusiones a partir de esta, así como posibles mejoras de la red.

## 1.5. Índice de abreviaturas

**OMS** Organización Mundial de la Salud

**IMS** Índice de masa corporal

**HGNA** Hígado graso no alcohólico

**EHNA** Esteatohepatitis no alcohólica

**SM** Síndrome metabólico

**ALT** Aspartato aminotransferasa

**RM** Resonancia magnética

**EM** Campo electromagnético

**RF** Campo de radiofrecuencia

**IRM** Imágenes por resonancia magnética

**IA** Inteligencia artificial

**AG** Algoritmo genético

**ADN** Ácido desoxirribonucleico

**KNN** k-Nearest Neighbour

**RNA** Red neuronal artificial

**MLP** MultiLayer Perceptron

**ECM** Error Cuadrado Medio

**CNN** Redes neuronales convolucionales

**RNN** Redes neuronales recurrentes

**FNN** Feed-forward neural network

**ReLU** Unidad lineal rectificada

**PreLU** Unidad lineal rectificada parametrizada

## Capítulo 2

# Fundamento Teórico

### 2.1. Obesidad y problemas de salud asociados

De acuerdo con la OMS la obesidad y el sobrepeso se definen como una acumulación anómala de grasa que puede ser dañina para la salud de la población.

Algunos de los métodos que más se ocupan para determinar la obesidad son los métodos antropométricos, talla, peso, pliegues cutáneos, el índice de masa corporal (IMC) y la inspección del paciente.[1].

El IMC es un indicador de la relación que existe entre el peso y la talla del paciente, se utiliza para poder identificar el sobrepeso y la obesidad en personas adultas. Este indicador se calcula dividiendo el peso del paciente en kilos por el cuadrado de su talla en metros ( $\text{kg}/\text{m}^2$ ).

$$\text{IMC} = \frac{\text{peso}(\text{kg})}{(\text{altura}(\text{m}))^2}$$

Una persona con un IMC igual o mayor a 25 es considerada con sobrepeso y con un IMC igual o superior a 30 es considerada una persona obesa y [3] [Tabla 2.1]. El sobrepeso y la obesidad son elementos importantes para considerables enfermedades crónicas, entre las que se encuentran la diabetes, el cáncer y las enfermedades cardiovasculares.

Clasificación	IMC ( $\text{Kg}/\text{m}^2$ )	Riesgo
Peso bajo	< 18.5	Bajo
Normal	18.5-24.9	Promedio
Sobrepeso	25-29.9	Aumentado
Obesidad	30-34.9	Moderado
Obesidad II	35-39.9	Alto
Obesidad III	$\geq 40$	Grave

Tabla 2.1: Clasificación de la obesidad y el sobrepeso según la OMS de acuerdo al IMC y su relación con comorbilidades. Fuente: Obesity and overweight. World Health Organization. <http://www.who.int/whr/2003/en/>.

#### 2.1.1. Clasificación

Dependiendo del origen de la enfermedad, la obesidad puede ser clasificada en dos tipos, la obesidad endógena y la obesidad exógena. La obesidad endógena es la menos usual de estas dos, solo entre el 5% y el 10% de las personas con obesidad la presentan, este tipo de obesidad se

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.1. OBESIDAD Y PROBLEMAS DE SALUD ASOCIADOS**

---

debe a problemas provocados por el mal funcionamiento de alguna glándula endocrina, como el síndrome de Cushing, el síndrome de ovario poliquístico, la tiroides (hipotiroidismo), diabetes mellitus, por mencionar algunos. Esta obesidad es causada por problemas internos, debido a esto algunas personas que la padecen no pueden perder peso.

Por otra parte, la obesidad exógena se debe a un abuso en la alimentación o a los hábitos sedentarios de cada persona. La obesidad exógena es la más común y no es provocada por ninguna enfermedad, es provocada por los hábitos de cada persona, y constituye entre el 90 y 95 % de todos los personas que sufren obesidad, esto significa que la mayor parte de las personas que la padecen es debido a un estilo de vida inadecuado [4].

### 2.1.2. Causas de la obesidad

La principal causa del sobrepeso y de la obesidad es un desequilibrio entre las calorías consumidas y gastadas. Se ha observado que a nivel mundial han ocurrido las siguientes sucesos, un aumento en la ingesta de alimentos que son abundantes en grasa; y una disminución de actividad física debido a la forma sedentaria de muchos trabajos, los modos de transporte y la urbanización.

Los cambios en los hábitos alimentarios y de actividad física son consecuencia de cambios ambientales y sociales asociados al desarrollo y de la falta de políticas de apoyo en sectores como la salud; la agricultura; el transporte; la planificación urbana; el medio ambiente; el procesamiento, distribución y comercialización de alimentos, y la educación [3].

Se considera que la obesidad es una enfermedad multifactorial, tanto que se reconocen factores metabólicos, ambientales, genéticos y endocrinológicos. Solo entre el 2 y el 3 % de las personas obesas tendrían como causa de la enfermedad alguna patología endocrinológica, de las cuales destaca el hipogonadismo, el hipotiroidismo y el síndrome de Cushing. Se ha estudiado que una acumulación excesiva de grasa corporal, puede inducir alteraciones en la regulación, metabolización y secreción algunas hormonas.

Existen estudios epidemiológicos que han detectado cierto factores que estan asociados con el sobrepeso y la obesidad [2], los cuales se detallan en la Tabla 2.2

Demográficos	Socioculturales	Biológicos	Conductuales	Actividad Física
>Edad	< Nivel educacional	> Paridad	> Ingesta alimentaria	Sedentarismo
Sexo femenino	< Ingreso económico		Tabaquismo	
Raza			Ingesta de alcohol	

Tabla 2.2: Factores Epidemiológicos asociados al exceso de peso, Fuente: Moreno M. *Definition and classification of obesity*. [Rev. Med. Clin. Condes - 2012; 23(2) 124-128]

### 2.1.3. Problemas de salud asociados.

Hay estudios que señalan que un IMC elevado es una importante causa de riesgo en enfermedades cardiovasculares, diabetes, osteoartritis, y el cáncer (de mama y colon) (Tabla 2.3). La obesidad en infantes esta asociada con una probabilidad más alta de padecer obesidad en la edad adulta, así como muerte prematura y algún tipo de discapacidad. La obesidad se relaciona con una disminución en la esperanza de vida de entre 6 a 20 años.[6].

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.1. OBESIDAD Y PROBLEMAS DE SALUD ASOCIADOS**

Cardiovascular	Neurológico
Enfermedad cardiovascular aterosclerótica Dislipidemia Hipertensión Insuficiencia cardíaca congestiva Insuficiencia venosa TVP/embolia pulmonar	Enfermedad vascular cerebral Hipertensión intracranial idiopática Demencia
Pulmonar	Trastornos musculoesqueléticos
Apnea del sueño Síndrome de hipoventilación Asma Hipertensión pulmonar Disnea	Osteoartritis Limitación de la movilidad Lumbalgia
Psicológico	Genitourinario
Depresión Baja autoestima Inadecuada calidad de vida Trastornos de alimentación	Síndrome de ovario poliquístico Alteraciones de la menstruación Esterilidad Incontinencia urinaria de esfuerzo Enfermedad renal terminal Hipogonadismo / Impotencia Glomerulopatía cáncer
Gastrointestinal	Metabólico
Colelitiasis Enfermedad por reflujo gastroesofágico Enfermedad de hígado graso no alcohólico Hernias	Diabetes tipo 2 Intolerancia a la glucosa Hiperuricemia/ gota Resistencia a la insulina Síndrome metabólico Deficiencia de vitamina D
Dermatológico	Cáncer
Acantosis nigricans Estrías de distensión Hirsutismo Estasis venosa Celulitis Intertrigo	Mama Colon Próstata Uterino

Tabla 2.3: Comorbilidad y complicaciones de la obesidad, Fuente: Catenacci VA, Hill JO, Wyatt HR. *The obesity epidemic*. Clin Chest Med 2009;30:415-444.

## 2.2. Hígado graso y patologías asociadas con la obesidad

El término hígado graso o enfermedad hepática por depósito de grasa se refiere a una afección del hígado caracterizada por la acumulación de ácidos grasos y triglicéridos en las células hepáticas (hepatocitos)[16][17].

El hígado graso no alcohólico (HGNA) incluye dentro de su presentación evolutiva a la esteatosis hepática, esteatohepatitis no alcohólica (EHNA), cirrosis y hepatocarcinoma[23, 15]. Se relaciona a obesidad, preferentemente abdominal, diabetes mellitus tipo II y síndrome metabólico (SM).

La HGNA es una afección definida por una acumulación excesiva de grasa en forma de triglicéridos (esteatosis) en el hígado (histológicamente  $>5\%$  de los hepatocitos). Además del exceso de grasa (esteatohepatitis), un subgrupo de pacientes con HGNA presenta daño e inflamación de los hepatocitos[13]. La cirrosis debida a EHNA es una razón cada vez más frecuente de trasplante hepático. Si bien la morbilidad y la mortalidad por causa hepática están muy aumentadas en los pacientes con EHNA, la correlación es aún mayor con la morbilidad y mortalidad por patología cardiovascular[16].

Según el método diagnóstico, la frecuencia del HGNA es del 3 al 36.9% en población general. Es más prevalente en pacientes en la cuarta a sexta décadas de la vida, de género masculino, raza hispana o con SM[16]. Un estudio multicéntrico que utilizó resonancia magnética para el diagnóstico de esteatosis, encontró una prevalencia de 45% de población hispana, 33% de población aria, 24% de afroamericanos, 42% de hombres y 24% de mujeres [29]. La incidencia de hígado graso en población adulta en la Ciudad de México es de 14%[29].

### 2.2.1. Patología de hígado graso no-alcohólico asociada a obesidad

La enfermedad de Hígado Graso No-Alcohólico es la causa más importante de enfermedad hepática crónica y es considerada la manifestación hepática del síndrome metabólico asociado a obesidad y diabetes mellitus tipo 2[22]. Se asocia a un amplio espectro de daño hepático, que incluye tanto la esteatosis simple o acumulación intracelular de triacilglicéridos (TAGs), como la inflamación, fibrosis y cirrosis (esteatohepatitis no-alcohólica). Los mecanismos implicados son de carácter multifactorial, siendo la resistencia a la insulina un factor común que genera retención de ácidos grasos y TAGs dentro de los hepatocitos, con la producción de radicales libres a nivel mitocondrial capaces de inducir estrés oxidativo, producción de citoquinas y necrosis [31].

#### **Alteraciones metabólicas, estrés oxidativo y resistencia a la insulina asociados a obesidad**

Los mecanismos implicados en la acumulación de TAGs a nivel hepático y el subsiguiente daño hepatocelular son de carácter multifactorial y su naturaleza se está empezando a establecer. En condiciones normales, los ácidos grasos (AGs) son el principal combustible para el hígado. Sin embargo, en patologías como la obesidad, la gran afluencia de hidratos de carbono y lípidos induce cambios significativos en el metabolismo intermediario en el hígado[31].

Los elevados niveles de insulina (hiperinsulinemia) no son capaces de suprimir el flujo de AGs, mostrando un importante nivel de resistencia periférica a la acción de la insulina. El aumento en el pool de AGs circulantes es uno de los principales factores determinantes en la patogénesis del HGNA.

Es así como la hiperglicemia e hiperinsulinemia asociadas promueven la síntesis de AGs a partir de la glucosa e inhiben la  $\beta$ -oxidación de AG, siendo estos AGs re-direccionados hacia la formación de TAGs[31][26]. Considerando que la cantidad de AGs que son exportados vía lipoproteínas de

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.2. HÍGADO GRASO Y PATOLOGÍAS ASOCIADAS CON LA OBESIDAD

---

muy baja densidad (VLDL) está limitada por la síntesis de sus componentes proteicos, el exceso de AGs es principalmente convertido en TAGs y depositados en los hepatocitos con el consumo de dietas hipercalóricas. Debido a que el hígado tiene una capacidad limitada para la acumulación de TAGs, el depósito de lípidos en condiciones de sobrealimentación determina elevados niveles de AGs saturados, los que se asocian a disfunción y muerte celular. En efecto, estudios experimentales indican que el exceso de AGs condiciona altas tasas de  $\beta$ -oxidación, con producción de especies reactivas del oxígeno (EROS: radical superóxido  $[O_2^-]$  y peróxido de hidrógeno  $[H_2O_2]$ ) a nivel de la cadena respiratoria mitocondrial, concomitantemente con la inducción de necrosis [31].

#### **Pérdida del control de la distribución metabólica de los ácidos grasos asociada a la obesidad**

El estrés oxidativo asociado a obesidad tendría un papel causal en el desarrollo de la RI, condición en la cual la captación de glucosa por el músculo y tejido adiposo y la inhibición de la producción de glucosa por el hígado no responden adecuadamente a la insulina, mientras que los efectos pro-lipogénicos de la insulina son mantenidos a nivel hepático [31, 42, 41]. Este fenómeno se asocia a un cambio en el tipo de fosforilación del receptor de insulina y sus sustratos, que normalmente ocurre en residuos de tirosina, a residuos de serina, mediada por la activación de diversas serina-quinatas activadas por estrés oxidativo. Esta modificación específica disminuye la fosforilación del receptor de insulina en tirosina y la vía de señalización intracelular de la hormona gatillando la RI, alteración que podría ser facilitada por la depleción de AGPI n-3, por pérdida del grado de insaturación de los fosfolípidos de membrana que es requerido para el funcionamiento normal del receptor de insulina [31].

Los AGPI n-3 ejercen sus efectos regulando el metabolismo de los lípidos en el hígado vía modificación en la transcripción génica, ya sea inhibiendo la expresión y procesamiento del factor pro-lipogénico proteína ligante al elemento regulador de esteroides-1c (SREBP-1c), y activando al receptor activado por proliferadores peroxisomales- $\alpha$  (PPAR- $\alpha$ ) que controla la expresión de los genes de enzimas de la oxidación de los AGs [31]. La disminución del contenido hepático de los AGPI n-3 en la obesidad se ha relacionado con:

- La mayor oxidación de EPA y DHA por el estrés oxidativo inducido
- La ingesta deficitaria de EPA, DHA y su precursor esencial el ácido  $\alpha$ -linolénico [38].
- La alteración en la síntesis hepática de AGPI n-3 debida a la menor actividad de la D-5 y D-6 desaturasas asociada a la RI [39].
- A la mayor ingesta de AGs insaturados de tipo trans que inhiben drásticamente a la D-6 desaturasa [31].

### 2.3. Resonancia magnética general

La resonancia magnética (RM) tiene como principio la interacción que existe entre un núcleo que posee espín y un campo magnético aplicado. La RM consta de tres principales elementos: un imán superconductor, un conjunto de tres bobinas de gradiente de campo magnético y un transmisor / receptor de radiofrecuencia. El imán superconductor generalmente tiene una fuerza de 3 Tesla, es decir  $6 \times 10^4$  veces más grande comparado con el campo magnético terrestre.

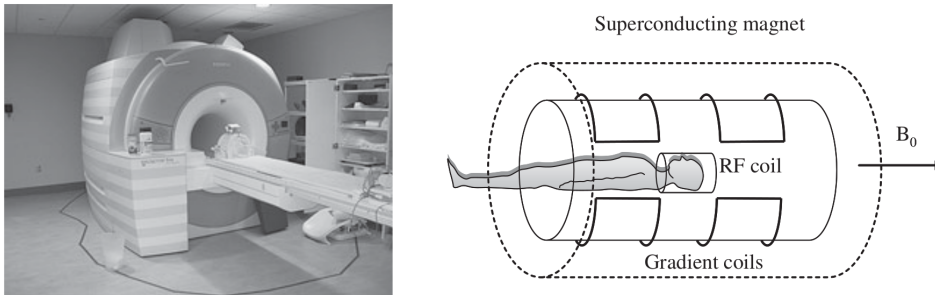


Figura 2.1: Un imán clínico de alto campo con cama para el paciente (Izquierda). Los tres componentes principales de un sistema de resonancia magnética, incluido el imán superconductor que produce un fuerte campo magnético ( $B_0$ ) en la dirección horizontal. Solo se muestra una de las tres bobinas de gradiente para mayor claridad (Derecha). Fuente: En *Introduction to Medical Imaging Physics, Engineering and Clinical Applications*, por N. B. Smith y A. Webb, 2001, por Cambridge University Press.

#### 2.3.1. Producción de magnetización neta

Los átomos constan de tres partículas fundamentales: electrones, protones y neutrones. Los protones poseen una carga positiva; los neutrones no tienen carga; y los electrones tienen carga negativa. Los protones y neutrones se encuentran en el núcleo de un átomo, mientras que los electrones se encuentran en las capas u orbitales que rodean el núcleo.

Las propiedades más utilizadas para categorizar elementos son: el número y el peso atómico. El número atómico se define como el número de protones existentes en el núcleo del átomo. Mientras que el peso atómico es la suma del número de protones y el número de neutrones. Los átomos que tienen el mismo número atómico pero difieren en sus pesos atómicos son denominados isótopos.

Como tercera propiedad del núcleo es el momento angular de espín o espín intrínseco. Con excepción del argón y el cerio, todos los elementos de la tabla periódica tienen al menos un isótopo natural que posee espín, esta es una propiedad intrínseca (Figura 2.3). En la naturaleza se encuentra un número limitado de valores para el giro; es decir, el espín,  $I$ , se cuantifica a algunos valores discretos. Estos valores van a depender del número atómico, del peso atómico del núcleo y de la suma de su momento angular. Hay tres grupos de valores para  $I$ : cero, valores semienteros y valores enteros.

Un núcleo tiene un valor entero para  $I$  (por ejemplo,  $I = 1, 2, 3$ ) cuando hay un número par de partículas en el núcleo, es decir, cuando el peso atómico es un número par, un núcleo tiene un valor semientero para  $I$  (por ejemplo,  $I = 1/2, 3/2, 5/2$ ) cuando el peso atómico es un número impar. La tabla 2.4 enumera la composición isotópica y de espín nuclear de algunos elementos que se encuentran comúnmente en los sistemas biológicos.

El núcleo  $^1\text{H}$ , que consta de un solo protón, es una opción natural para sondear el cuerpo mediante técnicas de RM por varias razones. Posee un espín de  $1/2$  y se conoce como el isótopo

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.3. RESONANCIA MAGNÉTICA GENERAL**

---

que más abunda de hidrógeno. Finalmente, la composición de los tejidos del cuerpo humano contienen esencialmente agua y grasa, los cuales contienen hidrógeno.




Figura 2.2: Un núcleo con espín con carga positiva produce un campo magnético conocido como momento magnético orientado en paralelo al eje de rotación (Izquierda). Esta disposición es análoga a una barra magnética en la que se considera que el campo magnético está orientado desde el polo sur hacia el norte (Derecha). Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002.

Además de poseer espín, un núcleo tiene un momento magnético de espín. Un núcleo con espín tiene dirección, y por tanto puede verse como un vector con una orientación y magnitud (Figura 2.3).

Constantes para núcleos seleccionados de interés biológico						
Elemento	Composición nuclear		Espín nuclear, I	Relación	% Abundancia Natural	$\omega$ a 1.5 T (MHz)
	Protones	Neutrones		Giromagnética $\beta$ (MHz T <sup>-1</sup> )		
<sup>1</sup> H, Protio	1	0	1/2	42.5774	99.985	63.8646
<sup>2</sup> H, Deuterio	1	1	1	6.53896	0.015	9.8036
<sup>3</sup> He	2	1	1/2	32.436	0.000138	48.6540
<sup>6</sup> Li	3	3	1	6.26613	7.5	9.39919
<sup>7</sup> Li	3	4	3/2	16.5483	92.5	24.8224
<sup>12</sup> C	6	6	0	0	98.90	0
<sup>13</sup> C	6	7	1/2	10.7084	1.10	16.0621
<sup>14</sup> N	7	7	1	3.07770	99.634	4.6164
<sup>15</sup> N	7	8	1/2	4.3173	0.366	6.4759
<sup>16</sup> O	8	8	0	0	99.762	0
<sup>17</sup> O	8	9	5/2	5.7743	0.038	8.6614
<sup>19</sup> F	9	10	1/2	40.0776	100	60.1164
<sup>23</sup> Na	11	12	3/2	11.2686	100	16.9029
<sup>31</sup> P	15	16	1/2	17.2514	100	25.8771
<sup>129</sup> Xe	54	75	1/2	11.8604	26.4	17.7906

Tabla 2.4: Fuente: Adaptado de Ian Mills (Ed.) *Quantities, Units, and Symbols in Physical Chemistry*, IUPAC, Physical Chemistry Division, Blackwell, Oxford, UK, 1989.

En general, las mediciones de RM se realizan en colecciones de espines similares, en lugar de un espín individual. Es útil considerar tal colección como espines individuales que actúan de forma

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.3. RESONANCIA MAGNÉTICA GENERAL

---

independiente (una imagen "subatómica") y como una entidad única (una imagen "macroscópica").

Consideremos un volumen arbitrario de tejido, el 80% de los tejidos humanos consiste en moléculas de agua [49], las moléculas de agua están compuestas por dos átomos de hidrógeno y un átomo de oxígeno. En la resonancia magnética el campo magnético interactúa con el protón del átomo de hidrógeno que compone a una molécula de agua, el efecto de la interacción de los dos protones orbitando al rededor del átomo de oxígeno es un efecto análogo al efecto Zeeman. [49]

Cada protón posee un vector de espín asociado de igual magnitud. Sin embargo, los vectores de espín para toda la colección de protones dentro de las moléculas de agua se encuentran orientados de manera aleatoria, es decir, en todas las direcciones. Realizar una suma vectorial de estos vectores de espín produce una suma igual a cero; es decir, no se observa magnetización neta en el tejido (Figura 2.4). Si un tejido se sitúa dentro de un campo magnético aplicado  $\mathbf{B}_0$ , los protones presentan precesión alrededor del campo magnético.

Los protones están ligeramente inclinados en dirección opuesta al eje del campo magnético, pero la dirección es paralela a  $\mathbf{B}_0$ . Esta precesión se produce debido a la interacción que existe entre el campo magnético con el momento magnético de espín. Por convención se definen  $\mathbf{B}_0$  y el eje de precesión del protón, de manera que estén orientados en la dirección  $z$  de un sistema de coordenadas cartesianas.




Figura 2.3: Imágenes subatómicas y macroscópicas de una colección de protones en ausencia de un campo magnético externo. En ausencia de un campo, los protones tienen sus vectores de espín orientados aleatoriamente (imagen subatómica, izquierda). La suma vectorial de estos vectores de espín es cero (imagen macroscópica, derecha). Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

El movimiento de cada protón se puede describir mediante un conjunto único de coordenadas perpendiculares ( $x$  e  $y$ ) y paralelas ( $z$ ) a  $\mathbf{B}_0$ . Las coordenadas perpendiculares o transversales son distintas de cero y varían a través del tiempo, pero la coordenada  $z$  es constante (Figura 2.5). La frecuencia de precesión es proporcional a la fuerza del campo magnético y se expresa con la Ecuación 2.1, conocida como la ecuación de Larmor:

$$\omega_0 = \gamma B_0 / 2\pi \tag{2.1}$$

donde se define  $\omega_0$  como la frecuencia de Larmor en megahercios (MHz),  $\mathbf{B}_0$  es la intensidad del campo magnético en Tesla (T) que experimenta el protón, y  $\gamma$  es una constante para cada núcleo en  $\text{s}^{-1}\text{T}^{-1}$ , conocida como relación giromagnética, para protones tiene un valor de 267.54 MHz / Tesla.




Figura 2.4: Dentro de un campo magnético, un protón precesa o alrededor del campo magnético. La dirección de precesión es paralela al campo magnético principal  $B_0$ . El componente  $z$  del vector de espín (proyección del espín sobre el eje  $z$ ) es el componente de interés porque no cambia en magnitud o dirección cuando el protón precesa. Los componentes  $x$  e  $y$  varían con el tiempo a una frecuencia  $\omega_0$  proporcional a  $B_0$  como se expresa en la ecuación (2.1). Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

Si se realiza una suma vectorial, como antes, para los vectores de espín dentro del campo magnético, los resultados serán ligeramente diferentes a los de la suma fuera del campo. En la dirección perpendicular a  $B_0$ , las orientaciones de espín siguen distribuidas aleatoriamente tal como estaban fuera del campo magnético, a pesar de la naturaleza variable en el tiempo de cada componente transversal. Todavía no hay magnetización neta perpendicular a  $B_0$ . No obstante, en la dirección paralela al campo magnético, existe un resultado diferente. A causa de que existe una orientación de precesión del protón que es constante con el tiempo, existe una interacción o acoplamiento constante diferente de cero entre el protón y  $B_0$ . Esto se conoce como el efecto Zeeman, en el efecto Zeeman se considera el átomo de hidrógeno. El modelo de la molécula del agua se puede considerar como el efecto Zeeman, al considerar los protones orbitando al rededor del oxígeno, en este caso los protones interactúan con el campo magnético, así como el electrón lo hace en el caso del átomo de hidrógeno [49]. Este acoplamiento provoca una diferencia de energía entre los protones alineados en paralelo a lo largo de  $B_0$  y los protones alineados en sentido antiparalelo o contra  $B_0$ . Esta diferencia de energía  $\Delta E$  es proporcional a  $B_0$  (Figura 2.6).

El resultado del efecto Zeeman es que los espines en las dos orientaciones, paralelo (conocido como espín hacia arriba) y antiparalelo (espín hacia abajo), poseen energías diferentes. La orientación que se encuentra paralela a  $B_0$  es la de menor energía. Para una colección de protones, más estarán orientados en paralelo a  $B_0$  de los que estarán orientados en sentido antiparalelo; es decir, hay una polarización inducida de la orientación del espín por el campo magnético.

La diferencia de energía ( $\Delta E$ ) que hay entre los dos estados esta dada por :

$$\Delta E = \frac{\gamma h B_0}{2\pi} \quad (2.2)$$

Donde  $h$  es la constante de Planck ( $6.63 \times 10^{-34} \text{ J s}$ ).

Para calcular el número relativo de protones en cada una de las dos configuraciones se puede utilizar la ecuación de Boltzmann:

$$\frac{N_{anti-parallel}}{N_{parallel}} = \exp - \left[ \frac{\Delta E}{kT} \right] = \exp - \left[ \frac{\gamma h B_0}{2\pi kT} \right] \quad (2.3)$$

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.3. RESONANCIA MAGNÉTICA GENERAL**

---

donde  $N_{parallel}$  y  $N_{anti-parallel}$  son el número de protones en la configuración paralela y antiparalela, respectivamente, y  $k$  es la constante de Boltzmann,  $1,381 \times 10^{-23} \text{ J K}^{-1}$  y  $T$  es la temperatura medida en Kelvin. Ya que el valor del exponente es muy pequeño, se puede hacer una aproximación de primer orden,  $e^{-x} \approx 1 - x$ :

$$\frac{N_{anti-parallel}}{N_{parallel}} = 1 - \left[ \frac{\gamma h B_0}{2\pi kT} \right] \quad (2.4)$$

La señal de RM depende de la diferencia de poblaciones entre los dos niveles de energía:

$$N_{parallel} - N_{anti-parallel} = N_{total} \frac{\gamma h B_0}{4\pi kT} \quad (2.5)$$

Donde  $N_{total}$  es el número total de protones. Es importante tener en cuenta que la resonancia magnética puede detectar solo la diferencia  $N_{parallel} - N_{anti-parallel}$ , y no el número total de protones.




Figura 2.5: Diagrama de Zeeman. En ausencia de un campo magnético (Izquierda), una colección de protones tendrá las configuraciones de componentes  $z$  iguales en energía para que no haya una alineación preferencial entre las orientaciones de giro hacia arriba y hacia abajo. En presencia de un campo magnético (Derecha), la orientación de giro hacia arriba (paralela a  $\mathbf{B}_0$ ) es de menor energía y su configuración contiene más protones que la configuración de giro hacia abajo de mayor energía. La diferencia de energía  $\Delta E$  entre los dos niveles es proporcional a  $\mathbf{B}_0$ . Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

Dado que la separación que hay entre los niveles de energía  $\Delta E$  es dependiente de la intensidad del campo,  $\mathbf{B}_0$ , el número exacto de espines en cada nivel va a ser dependiente de  $\mathbf{B}_0$  y va a aumentar, cuando  $\mathbf{B}_0$  aumenta. Para una colección de protones a temperatura corporal (310 K) a 1.5 T, normalmente habrá un exceso de  $1:10^6$  protones en el nivel inferior de los aproximadamente  $10^{25}$  protones dentro del tejido [40]. Este número desigual de protones en cada nivel de energía significa que la suma vectorial de espines será distinta de cero y estará dirigida de forma paralela al campo magnético. Es decir, el tejido se magnetizará o polarizará en presencia del campo  $\mathbf{B}_0$  y tendrá un valor  $\mathbf{M}_0$ , llamado magnetización neta. La orientación de esta magnetización neta será en la misma dirección que el campo  $\mathbf{B}_0$  y no cambiará con respecto al tiempo, es decir, será constante. La magnitud de  $\mathbf{M}_0$ , para los tejidos del cuerpo, es proporcional a  $\mathbf{B}_0$ :

$$\mathbf{M}_0 = \chi \mathbf{B}_0 \quad (2.6)$$

donde  $\chi$  se conoce como la susceptibilidad magnética en masa o simplemente la susceptibilidad magnética. Esta disposición con  $\mathbf{M}_0$  ordenado a lo largo del campo magnético sin componente transversal, es la configuración normal o de equilibrio de los protones. Esta configuración de espines posee la energía más baja y es el orden al que los protones intentarán regresar naturalmente después de alguna perturbación, como lo es la absorción de energía. Esta magnetización inducida,  $\mathbf{M}_0$ , es la fuente principal para los experimentos de RM.

### 2.3.2. Conceptos de Resonancia Magnética

Para obtener una señal de RM, se debe suministrar energía con un valor específico  $\Delta E$ , dado por la ecuación (2.2), para estimular las transiciones entre los niveles de energía. Se suministra energía como un campo electromagnético (EM), generalmente denominado campo de radiofrecuencia (RF), cuya frecuencia ( $f$ ) se puede calcular a partir de la relación de De Broglie,  $\Delta E = hf$ :

$$hf = \Delta E = \frac{\gamma \hbar \mathbf{B}_0}{2\pi} \quad (2.7)$$

$$\Rightarrow f = \frac{\gamma \mathbf{B}_0}{2\pi} \quad (2.8)$$

o

$$\omega = \gamma \mathbf{B}_0 \quad (2.9)$$

En Imágenes por resonancia magnética (IRM), la energía se aplica como un pulso corto de RF, con la dirección del componente magnético del campo de RF orientado a  $90^\circ$  en la dirección de  $\mathbf{B}_0$ , como se muestra en la Figura 2.7. Aplicando el mismo análisis clásico que para la precesión de protones, el componente magnético del pulso de RF, denominado campo  $\mathbf{B}_1$ , produce un par que hace que la magnetización neta gire hacia el plano  $xy$  como se indica en la Figura 2.7. Hay que tener en cuenta que si el campo  $\mathbf{B}_1$  es aplicado a lo largo del eje  $x$ , el vector de momento magnético gira hacia el eje  $y$ .

#### La base de la detección de señales de RM

En el caso más simple, el detector de RM consiste en un par de bucles conductores (de alambre de cobre, por ejemplo) colocados cerca del paciente en un ángulo de  $90^\circ$  entre sí. La ley de inducción de Faraday dice que se induce un voltaje (V) en cada uno de estos bucles con un valor proporcional a la tasa de cambio en el tiempo del flujo magnético  $d\varphi$ :

$$V \propto -\frac{d\varphi}{dt} \quad (2.10)$$




Figura 2.6: La aplicación de un pulso de RF alrededor del eje  $x$  hace girar la magnetización desde la dirección  $z$  hacia el eje  $y$ . Si la intensidad y duración del pulso de RF se eligen para producir un pulso de  $90^\circ$ , entonces la magnetización se encuentra directamente a lo largo del eje  $y$  (Izquierda). Cuando el pulso de RF se apaga, la magnetización precesa alrededor del eje  $z$  a la frecuencia de Larmor  $\omega_0$  (Derecha). Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

### 2.3.3. Tiempos de relajación: $T_1$ y $T_2$

Aplicar un pulso de RF crea un estado de no equilibrio al agregar energía al sistema. Una vez que se ha apagado el pulso, el sistema debe relajarse y volver al equilibrio térmico.

La figura 2.8 muestra lo que sucede con la magnetización después de la aplicación de un pulso de  $90^\circ$  alrededor del eje  $x$ .

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.3. RESONANCIA MAGNÉTICA GENERAL**

---

Es importante señalar que hay dos tiempos de relajación que gobiernan el retorno al equilibrio de la componente  $z$  y las componentes  $x$  e  $y$ , respectivamente. Estos se conocen como relajación  $T_1$  (que afecta solo a la magnetización  $z$ ) y relajación  $T_2$  (que afecta solo a la magnetización  $x$  e  $y$ ). También se denominan relajación de spin-lattice ( $T_1$ ) y espín-espín ( $T_2$ ).

La relajación de RM se describe matemáticamente, haciendo uso de ecuaciones diferenciales de primer orden, que se conocen como ecuaciones de Bloch [50]. Las soluciones de estas ecuaciones dan las relaciones siguientes: después de un pulso de RF de ángulo de punta arbitrario  $\alpha$ , el valor de  $M_z$  en un tiempo  $t$  esta dado por:

$$M_z(t) = M_0 \cos\alpha + (M_0 - M_0 \cos\alpha) \left(1 - e^{-\frac{t}{T_1}}\right) \quad (2.11)$$

Por ejemplo, después de un pulso de  $90^\circ$  el valor de  $M_z$  esta dado por :

$$M_z(t) = M_0 \left(1 - e^{-\frac{t}{T_1}}\right) \quad (2.12)$$




Figura 2.7: Vector de magnetización después de un pulso de RF de  $90^\circ$  alrededor del eje  $x$  (Izquierda). La relajación  $T_1$  y  $T_2$  de la magnetización un cierto tiempo después de que se ha aplicado el pulso da como resultado un componente  $M_z$  aumentado y un componente  $M_y$  reducido, respectivamente (Centro). Después de un tiempo más, los componentes  $M_z$  y  $M_y$  casi han regresado a sus valores de equilibrio de  $M_0$  y cero, respectivamente (Derecha). Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

Los diferentes tejidos tienen diferentes valores de  $T_1$ , y los tejidos enfermos a menudo tienen un tiempo de relajación de  $T_1$  sustancialmente alterado en comparación con el tejido sano, y estas diferencias forman una base para introducir contraste en la imagen de RM. Los valores de  $T_1$  de tejido para 1.5 y 3 Tesla se muestran en la Tabla 2.5. Se puede ver que los valores de  $T_1$  dependen no solo del tipo de tejido sino también de la intensidad del campo magnético.

La figura 2.9 muestra la dependencia del tiempo de la magnetización  $M_z$  después de un pulso de  $90^\circ$  para dos tejidos con diferentes valores de  $T_1$ .

El segundo tiempo de relajación,  $T_2$ , gobierna el retorno de los componentes  $M_x$  y  $M_y$  de la magnetización a sus valores de equilibrio térmico de cero. Si se aplica un pulso de RF de ángulo de punta arbitrario  $\alpha$  a lo largo del eje  $x$ , el valor de  $M_y$  en el tiempo  $t$  después del pulso de RF viene dado por:

$$M_y(t) = M_0 \sin\alpha \exp\left(-\frac{t}{T_2}\right) \quad (2.13)$$

Como en el caso de los tiempos  $T_1$ , los diversos tejidos del cuerpo tienen diferentes valores de  $T_2$ . Cabe señalar que no existe una correlación directa entre los valores de  $T_1$  y  $T_2$ , una  $T_1$  larga no

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.3. RESONANCIA MAGNÉTICA GENERAL**

---

significa necesariamente una  $T_2$  larga. Lo único que es universalmente cierto es que  $T_1$  es siempre mayor que  $T_2$ .

Tejido	$T_1$ (1.5T)	$T_1$ (3T)	$T_2$ (1.5T)	$T_2$ (3T)
Cerebro (Materia blanca)	790	1100	90	60
Cerebro (Materia gris)	920	1600	100	80
Hígado	500	800	50	40
Músculo esquelético	870	1420	60	30
Lípido (subcutáneo)	290	360	160	130
Cartílago	1060	1240	42	37

Tabla 2.5: Tiempos de relajación del tejido a 1.5 y 3 Tesla. Fuente: *Introduction to Medical Imaging Physics, Engineering and Clinical Applications*, por N. B. Smith y A. Webb, 2001, por Cambridge University Press.




Figura 2.8: La recuperación de la magnetización  $M_z$  en función del tiempo después de un pulso de  $90^\circ$  para un tejido con tiempo de relajación  $T_1$  corto (línea continua) y tiempo de relajación  $T_1$  largo (línea discontinua). Cuando  $t = 5 * T_1$ ,  $M_z \sim 99\% M_0$ , que se supone que es una recuperación completa

### 2.3.4. Imagen de resonancia magnética

La resonancia magnética como método de imagen aporta grandes ventajas, una de ellas es la posibilidad de obtener de forma clara una imagen tomográfica en cualquier plano del espacio, esto lo hace mediante el uso de gradientes magnéticos. Si consideramos el caso en el que el campo magnético dentro del imán es uniforme, todos los núcleos captarían la energía de RF a la misma frecuencia. Razón por la cual para lograr una excitación que sea selectiva de distintos planos se tiene que establecer un gradiente magnético en la dirección perpendicular a los planos escogidos. Estos gradientes son perturbaciones lineales a  $\mathbf{B}_0$ , de modo que el campo magnético exacto depende linealmente de la ubicación dentro del imán:

$$\mathbf{B}_i = \mathbf{B}_0 + \mathbf{G}_T \otimes \mathbf{r}_i \quad (2.14)$$

donde  $\mathbf{B}_i$  es el campo magnético en la ubicación  $\mathbf{B}_i$  y  $\mathbf{B}_i$  es la amplitud total del gradiente.

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.3. RESONANCIA MAGNÉTICA GENERAL

---

En la resonancia magnética clínica, los gradientes del campo magnético producen variaciones lineales principalmente en una sola dirección, de modo que el producto del tensor en la ecuación 2.14 se puede reducir a una representación vectorial. Se utilizan tres gradientes físicos, uno en cada una de las direcciones  $x$ ,  $y$  y  $z$ , están diseñados de manera que no haya contribución adicional al campo magnético en el isocentro ( $z = 0$ ,  $y = 0$ ,  $x = 0$ ) de los gradientes, lo que significa que el campo magnético en esta posición es simplemente  $\mathbf{B}_0$ . Por convención, el eje  $y$  corresponde a la dirección anterior / posterior, y el eje  $x$  a la dirección izquierda / derecha de un paciente acostado en el imán. A cada uno se le asigna, a través del software operativo, uno o más de los tres gradientes “lógicos” o funcionales necesarios para obtener una imagen: selección de cortes, lectura o codificación de frecuencia y codificación de fase.

La unión de los pulsos de gradiente, los pulsos de RF, los períodos de muestreo de los datos y el tiempo entre cada uno de ellos, para obtener una imagen se conoce como secuencia de pulsos.

La presencia de gradientes de campo magnético requiere una versión ampliada de la ecuación de Larmor.

$$\omega_i = \gamma(B_0 + \mathbf{G} \cdot \mathbf{r}_i) \quad (2.15)$$

donde  $\omega_i$  representa la frecuencia del protón en la posición  $\mathbf{r}_i$  y  $\mathbf{G}$  es un vector que representa la dirección y la amplitud total del gradiente.

Se puede considerar a la imagen de RM como un mapa de la fase y la frecuencia de los protones que fueron generados por los campos magnéticos en cada punto de la imagen de RM. La imagen mostrada consta de elementos de imagen digital que representan elementos de volumen del tejido..

#### Selección de cortes

El paso inicial en la resonancia magnética es la ubicación de la excitación de RF en un área del espacio, que se consigue por el uso el uso de excitación selectiva en frecuencia junto con un gradiente que se conoce como gradiente de selección de cortes,  $\mathbf{G}_{SS}$ . La dirección del gradiente ( $x$ ,  $y$ ,  $z$ ) determina la orientación del corte, mientras que la amplitud del gradiente junto con ciertas características del pulso de RF determinan tanto el grosor del corte como la posición del corte.

Cuando dicho pulso se transmite en presencia del gradiente de selección de cortes, una región estrecha de tejido logra la condición de resonancia y absorbe la energía de RF. El tiempo de duración del pulso de RF como su amplitud determinan la cantidad de rotación del protón resultante. El grosor del corte está determinado por la amplitud del gradiente  $\mathbf{G}_{SS}$  y el ancho de banda de las frecuencias  $\Delta\mathbf{G}_{SS}$  incorporadas en el pulso de RF:

$$\Delta\omega = \gamma\Delta(\mathbf{G}_{SS} * \text{Grosor}) \quad (2.16)$$

$\Delta\omega$  se fija para que el grosor del corte se cambie modificando la amplitud de  $\mathbf{G}_{SS}$  (Figura 2.10). Los cortes más delgados requieren  $\mathbf{G}_{SS}$  más grandes. Una vez que  $\mathbf{G}_{SS}$  está determinado por el grosor del corte, la frecuencia central se calcula usando la Ecuación 2.15 para traer la ubicación deseada en resonancia.

La orientación del corte está determinada por el gradiente físico particular. Se define de tal manera que la orientación del gradiente sea perpendicular o normal a la superficie del corte, de forma tal que cada protón que se encuentre dentro del corte experimente el mismo campo magnético total independientemente de la posición que tenga dentro del corte.




Figura 2.9: Para un rango dado (ancho de banda) de frecuencias incluidas en el pulso de RF, el grosor de corte deseado está determinado por la amplitud del gradiente de selección de corte. La interfaz de usuario normalmente permite la variación del grosor del corte, que se logra aumentando o disminuyendo la amplitud del gradiente de selección del corte, según corresponda. Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002




Figura 2.10: Proceso de selección de cortes. En presencia de un gradiente ( $G_{SS}$ ), el campo magnético total que experimenta un protón y su frecuencia resonante resultante dependen de su posición, según la Ecuación 3.15. El tejido ubicado en la posición  $z_i$  absorberá la energía de radiofrecuencia transmitida con una frecuencia central  $\omega_i$ . Cada posición tendrá una frecuencia de resonancia única. El grosor de corte  $\Delta z$  está determinado por la amplitud de  $G_{SS}$  y por el ancho de banda de las frecuencias transmitidas  $\Delta w$ . Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

### Lectura o codificación de frecuencia

La parte de detección de señal de la medición de IRM se conoce como lectura o codificación de frecuencia.

En una secuencia de pulsos de imágenes, siempre se detecta la señal de RM, en presencia de un gradiente conocido como gradiente de lectura  $G_{RO}$ , que produce una de las dos dimensiones visuales de la imagen en la película. Una secuencia de pulsos típica utiliza cierta forma de excitación, después de la excitación, la magnetización neta dentro del corte se orienta transversalmente a  $\mathbf{B}_0$  y precesará con una frecuencia  $\omega_0$ . Los procesos  $T2^*$  inducen el desfase de esta magnetización transversal. Este desfase puede invertirse parcialmente para formar un eco por medio de la aplicación de un pulso de RF de  $180^\circ$ , un pulso de gradiente o ambos. A medida que se forma el eco, el gradiente de lectura se aplica perpendicularmente a la dirección del corte. Bajo la influencia de este nuevo campo de gradiente, los protones comienzan a precesar a diferentes frecuencias dependiendo de su posición dentro de él. Cada una de estas frecuencias se superpone al eco. En el momento deseado, la señal de eco es medida por la bobina receptora y digitalizada para la posterior transformación de Fourier.

La magnitud de  $G_{RO}$  está determinada por dos parámetros que se definen por el usuario: el

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.3. RESONANCIA MAGNÉTICA GENERAL**

---

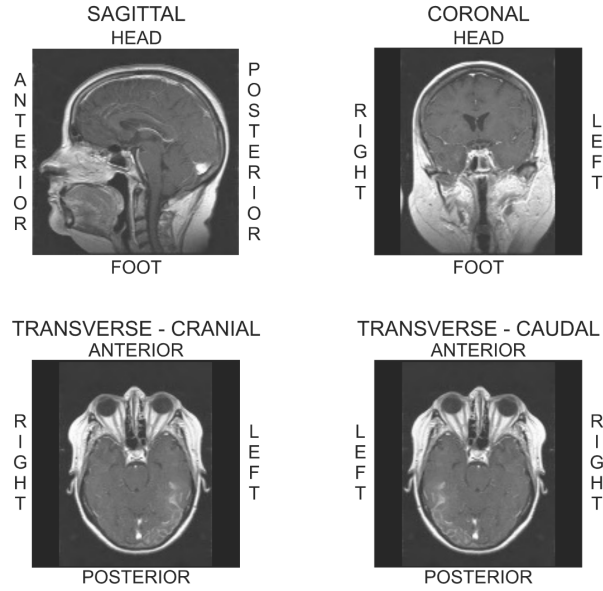


Figura 2.11: Imágenes en direcciones de corte estándar: sagital, coronal y transversal o axial. Para imágenes transversales, son posibles dos direcciones de visualización: craneal y caudal. Fuente: Brown MA y Semelka RC. *MRI Basic Principles and Applications*. Wiley-Liss, 2002

campo de visión en la dirección de lectura,  $FOV_{RO}$ , y la frecuencia de Nyquist,  $\omega_{NQ}$ , para la imagen, a menudo referida como el ancho de banda del receptor.

$$\Delta\omega_{RO} = 2 * \omega_{NQ} = \gamma\Delta(G_{RO} * FOV_{RO}) \quad (2.17)$$

donde  $\omega_{RO}$  es el rango total de frecuencias en la imagen.  $G_{RO}$  se elige de modo que los protones ubicados en el borde del  $FOV_{RO}$  precesen a la frecuencia de Nyquist para la imagen. Se consiguen  $FOV_{RO}$  más pequeños aumentando  $G_{RO}$ , manteniendo la frecuencia de Nyquist y, por lo tanto, el ancho de banda de frecuencia total constante.

La resolución que tiene una imagen de RM, se puede expresar de dos formas: resolución espacial o resolución de frecuencia. La resolución espacial, expresada como el tamaño del vóxel con unidades de mm / píxel, se deriva de dos parámetros de usuario:  $FOV_{RO}$  y el número de puntos de muestra de lectura en la matriz de adquisición,  $N_{RO}$ :

$$VOX_{RO} = FOV_{RO}/N_{RO} \quad (2.18)$$

La resolución de frecuencia, con unidades de Hz / píxel, se basa en  $N_{RO}$  y el ancho de banda total  $\omega_{RO}$  para la imagen:

$$\text{Ancho de banda de píxeles} = \Delta\omega_{RO}/N_{RO} = 2 * \omega_{NQ}/N_{RO} \quad (2.19)$$

Es posible mejorar la resolución de frecuencia para la medición independientemente de la resolución espacial aumentando el tiempo de muestreo total utilizado para medir la señal. Esto reduce la frecuencia de Nyquist para la imagen y el ruido de fondo que contribuye a la medición.

**Codificación de fase**

La tercera dirección en una imagen de RM es la dirección de codificación de fase. El gradiente de codificación de fase,  $\mathbf{G}_{PE}$ , es perpendicular tanto a  $\mathbf{G}_{SS}$  como a  $\mathbf{G}_{RO}$  y es el único gradiente

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.3. RESONANCIA MAGNÉTICA GENERAL

---

que cambia de amplitud durante el ciclo de adquisición de datos de una secuencia de imágenes bidimensional (2D) estándar. Se supone que cualquier variación de amplitud de señal detectada de una adquisición a la siguiente es causada por la influencia de  $\mathbf{G}_{PE}$  durante la medición.

El principio de codificación de fase tiene como base el hecho de que la precesión de protones es periódica por naturaleza. Antes de la aplicación de  $\mathbf{G}_{PE}$ , un protón dentro de un corte precesa a la frecuencia base  $\omega_0$ . En presencia de  $\mathbf{G}_{PE}$ , su frecuencia de precesión va a aumentar o disminuir con base a la Ecuación 2.15. Cuando  $\mathbf{G}_{PE}$  se apaga, la precesión de protones vuelve a su frecuencia original, pero está adelante o atrás en la fase en relación con su estado anterior. La cantidad de cambio de fase inducido depende de la magnitud y duración de  $\mathbf{G}_{PE}$  que experimentó el protón y la ubicación del protón. Se obtiene la información de la imagen de RM repitiendo tanto la excitación del corte como la detección de la señal varias veces, variando la amplitud de  $\mathbf{G}_{PE}$ . La segunda transformación de Fourier en la imagen convierte la amplitud de la señal en cada frecuencia de lectura de una función de  $\mathbf{G}_{PE}$  a una función de fase.

La resolución espacial en la dirección de codificación de fase es dependiente de dos parámetros que son seleccionados por el usuario: el campo de visión en la dirección de codificación de fase  $FOV_{PE}$  y el número de pasos de codificación de fase en la matriz de adquisición,  $N_{PE}$ . El primero,  $FOV_{PE}$ , está determinado por el cambio en  $G_{PE}$  de un paso al siguiente. Para un protón ubicado en el  $FOV_{PE}$  elegido, cada paso de codificación de fase induce la mitad de un ciclo ( $180^\circ$ ) de cambio de fase en relación con el paso de codificación de fase anterior, asumiendo una duración de pulso constante.  $N_{PE}$  determina el número total de ciclos de cambio de fase ( $N_{PE} / 2$ ) que se producen en el borde del  $FOV$  y, por consiguiente, la frecuencia máxima ( $\omega_{NQ}$ ) en la dirección de codificación de fase para la duración del pulso dado. Dicha resolución espacial en la dirección de codificación de fase se expresa como el tamaño del vóxel y se mide en mm / píxel:

$$VOX_{PE} = FOV_{PE}/N_{PE} \tag{2.20}$$

Se obtiene la resolución aumentada ya sea reduciendo el  $FOV_{PE}$ , o bien, aumentando  $N_{PE}$ . Se logra la reducción del  $FOV$ , aumentando el cambio de amplitud del gradiente de un  $G_{PE}$  al siguiente.

## 2.4. Inteligencia Artificial en general

Inteligencia artificial (IA) es un término que toma forma a mediados del año 1900, en las tablas 2.6-7 se exponen algunas definiciones de la IA. Estas van a variar respecto a dos alcances principales. Las definiciones que muestra la tabla 2.6 se refieren a los procesos mentales y de razonamiento, mientras que las definiciones que detalla la tabla 2.7 estan correlacionadas con la conducta. A la izquierda de la tabla 2.6 se encuentran las definiciones que calibran la condición que se quiere con base en la eficiencia humana, mientras que las definiciones que se muestran a la derecha, lo hacen con base en el concepto de inteligencia ideal, que se denomina racionalidad. Se considera que un sistema es racional si, función de su conocimiento, hace lo correcto[51].

“La interesante tarea de lograr que las computadoras piensen ... máquinas con mente, en su amplio sentido literal” (Haugeland, 1985).	“El estudio de las facultades mentales mediante el uso de modelos computacionales” (Charniak y McDermott, 1985).
“[La automatización de] actividades que vinculamos con procesos de pensamiento humano, actividades tales como toma de decisiones, resolución de problemas, aprendizaje, ...” (Bellman, 1978).	“El estudio de los cálculos que permiten percibir, razonar y actuar” (Winston, 1992).
“El arte de crear máquinas con capacidad de realizar funciones que realizadas por personas requieren de inteligencia” (Kurzweil, 1990).	“Un campo de estudio que se enfoca en la explicación y emulación de la conducta inteligente en función de procesos computacionales” (Schalkoff, 1990).
“El estudio de cómo lograr que las computadoras realicen tareas que, por el momento, los humanos hacen mejor” (Rich y Knight, 1991).	“La rama de la ciencia de la computación que se ocupa de la automatización de la conducta inteligente” (Luger y Stubblefield, 1993).

Tabla 2.6: Algunas definiciones de las IA [51]

Sistemas que piensan como humanos.	Sistemas que piensan racionalmente.
Sistemas que actúan racionalmente.	Sistemas que actúan como humanos.

Tabla 2.7: Categorías en que se clasifica la IA. Fuente: [51]

A continuación se detallan cada una de las cuatro maneras en las que es posible analizar y/o estudiar la IA.

### 1. Actuar como humano: el enfoque de la prueba de Turing.

En 1950 Alan Turing propuso la prueba que lleva su nombre, prueba Turing, mediante esta prueba se ofrece una definición operativa de lo que es la inteligencia.

La definición de Turing de una conducta inteligente es descrita como la capacidad de lograr eficiencia en las actividades que sean de tipo cognoscitivo. Esta prueba consistía en que un humano interrogara a una computadora por medio de un teletipo; se consideraba aprobada si el evaluador era capaz de determinar si, quien había respondido las preguntas al otro lado de la terminal, era un humano o una computadora[51]. En la prueba de Turing se impidió la interacción directa entre la computadora y el evaluador. Sin embargo, en la llamada prueba total de Turing se emplea un video en el sentido de que el evaluador tenga la destreza de calificar la capacidad de percepción del evaluado.

Para que la prueba total de Turing sea aprobada, son necesarias dos cosas en la computadora:

- Vista, para percibir objetos.
- Robótica, para el desplazamiento de objetos.

### **2. Pensar como humano: modelo cognoscitivo.**

Para decir que un programa emplea algún tipo de razonamiento humano, primero se tiene que definir como piensan los humanos, y para hacer eso habrá que adentrarse en el funcionamiento de la mente de los humanos.

Existen dos maneras de lograrlo:

- Por la realización de experimentos psicológicos.
- Por la introspección.

Una vez que se tenga una teoría estructurada sobre la mente, se puede proceder a expresarla en un programa por computadora. Si los datos de entrada o salida del programa y la duración de su desarrollo competen a los de la conducta de los humanos, entonces, hay evidencia de que algunos de los mecanismos de tal programa funcionan en los humanos[51].

### **3. Pensar racionalmente: Las leyes del pensamiento.**

Aristóteles fue uno de los primeros en pretender codificar cual era “la forma correcta de pensar”, en otras palabras, establecer procesos de pensamiento irrefutables. Sus silogismos son bosquejos de estructuras de argumentación por las cuales se llega siempre a conclusiones correctas si se parte de proposiciones correctas. Dichas leyes del pensamiento debían dirigir la forma de operar de la mente, con esto se comenzó el campo de la Lógica[51].

A finales del año 1800 se desarrolló la lógica formal y a principios del siglo siguiente permitió poseer una notación clara para representar afirmaciones que están relacionadas con todo lo que existe en el mundo. En 1965 ya existían programas que podían describir un problema en notación lógica y podían resolverlo y encontrarle una solución, con la condición de que esta existiera (de otra forma el programa no pararía de buscarla)[51].

Este enfoque exhibe dos obstáculos. El primero, la dificultad para expresar un conocimiento informal en los términos formales que demanda la notación lógica. En segundo lugar, hay una gran diferencia entre la posibilidad de resolver un problema “en principio”, y realmente hacerlo en la práctica.

### **4. Actuar en forma racional: el enfoque del agente racional**

Actuar racionalmente implica actuar de tal manera que se consigan los objetivos deseados con base en ciertas suposiciones. Un agente es algo capaz de percibir y actuar. De acuerdo con este enfoque, se considera la IA como el estudio y construcción de agentes racionales[51, 55].

En el caso del enfoque de la IA según las “leyes del pensamiento”, todo el énfasis se ponía en hacer inferencias correctas. La obtención de estas inferencias a veces forma parte de lo que se considera

un agente racional, sin embargo, el efectuar una inferencia correcta no siempre depende de la racionalidad. Hay situaciones en las que no existe algo que se pueda considerar lo que correctamente debería hacerse, y sin embargo hay que decidirse por una trayectoria de acción.

Analizar la IA tiene dos ventajas si se adopta el enfoque del diseño de un agente racional. La primera, es más general que el enfoque de las “leyes del pensamiento”, dado que el efectuar inferencias correctas es sólo un mecanismo útil para garantizar la racionalidad, pero no es un mecanismo necesario. La segunda, esta dirigida a la forma en la que se ha llevado a cabo el avance científico que los enfoques basados en la conducta o pensamiento humanos [51].

### **2.4.1. Antecedentes de la Inteligencia Artificial**

Aristóteles dio los primeros pasos en dirección a la IA, cuando explicó y codificó algunos tipos de razonamiento a los cuales llamó silogismos. Ramón Llull construyó una máquina capaz de responder todas las preguntas, esta máquina era un conjunto de ruedas que fue llamado *Ars Magna*.

Por otro lado, George Boole en 1854 desarrolló los fundamentos de la lógica proposicional, su objetivo fue recoger indicios sobre la naturaleza y la formación de la mente humana. Después, Gottlob Frege inventó una gran parte de lo que hoy se conoce como cálculo proposicional [51].

En 1962 Frank Rosenblatt investigó el uso de redes llamadas *perceptrones*.

Por el final del año 1970 y el principio de 1980, algunos programas que fueron desarrollados tenían una capacidad mayor y conocimientos necesarios para imitar el desempeño humano de expertos en diferentes tareas. El primer programa desarrollado en este sentido fue DENDRAL. Este era un sistema de predicción de la estructura de las moléculas orgánicas, solo consideraba el análisis de espectrograma de masa y su fórmula química .

Un programa que llevaba el nombre de *Deep Blue* en 1997, derrotó Garry Kasparov, quien es campeón mundial de ajedrez . Por otra lado, en 1963 Larry Roberts desarrolló uno de los primeros programas de análisis de escena. Este trabajo antecedió una amplia labor de máquinas de visión artificial [55].

### **2.4.2. Ramas que componen la Inteligencia Artificial**

La ciencia de la IA esta compuesta por varios elementos, que se pueden diferenciar en tres ramas:

- Lógica difusa
- Redes neuronales artificiales
- Algoritmos genéticos

#### **LÓGICA DIFUSA**

Las computadoras ocupan datos que al final, son cadenas de unos (1) y ceros (0), además utilizan proposiciones que tienen el valor de verdadero o falso. Mientras que el cerebro humano puede razonar con información que puede tener incertidumbre o algún juicio de valor como: “la velocidad es rápida”. La lógica difusa usa términos en este sentido, como “frío” o “húmedo” [51].

En el año 1900 Bertrand Russell continuó con el estudio de la lógica difusa cuando retomó una paradoja griega antigua que afirmaba que todos los cretenses mienten. Si miente, dice la

verdad y no miente. Si no miente, entonces dice la verdad y miente. En ambos casos se conduce a una contradicción ya que la frase es a la vez cierta y falsa. En este caso, la lógica clásica es vencida, mientras que la lógica difusa dice que 50 % de la frase es cierta y 50 % de frase es falsa [51].

En 1965 Lotfi A. Zadeh, publicó *Fuzzy Sets*, en este artículo se describe la teoría de los conjuntos difusos y por difusión de la lógica difusa, debido a esto el campo recibe el nombre gracias a este trabajo.

A mediados de los 70's Ebrahim H. Mamdani utilizó la lógica difusa. Diseñó un controlador difuso para un motor a vapor. A partir de ahí, cualquier sistema, ya sea matemático o computacional, que razona utilizando lógica difusa es sinónimo de esta. La idea de sistemas difusos radica en que los valores verdaderos se denotan en un número que se encuentra en el intervalo  $[0.0, 1.0]$ , donde el valor 0.0 representa una falsedad total, mientras que el valor 1.0 simboliza una verdad absoluta[55].

La lógica difusa tiene como objetivo principal crear un sistema que tenga fundamentos en el pensamiento y comportamiento de los seres humanos. La clave de la lógica difusa se apoya en la práctica. Este sistema toma el conocimiento del experto y crea sus reglas para realizar una propuesta.

La lógica difusa consta de tres etapas para obtener el resultado deseado.

Primera etapa: Proceso donde las variables tienen un grado de incertidumbre metalingüístico. Por lo cual, el rango de valores de cada variable puede catalogarse por conjuntos difusos. Se busca definir en qué punto el valor que se adquiere pertenece a un conjunto difuso. Segunda etapa: En esta etapa se proponen reglas de inferencia que contribuirán que el sistema se comporte de la forma deseada según los objetivos del usuario. Dichas reglas se determinan con ayuda de un experto ya que estas determinarán una consecuencia que caracterizará a la salida. Tercera etapa: Proceso para determinar los valores óptimos de salida. Consiste en pasar el grado de pertenencia a un valor real.

## **REDES NEURONALES ARTIFICIALES**

Warren McCulloch y Walter Pitts propusieron en el año 1943 el primer modelo simple sobre la neurona. B. Widrow y M. E. Hoof. dirigieron el desarrollo de redes neurales en los 50's y los 70's, trabajaron con la llamada *Adaline* (Adaptive Linear Element)[55].

En 1959 Frank Rosenblatt construyó el perceptrón, que era una máquina neural simple, tenía una matriz con fotoceldas que se encontraban conectadas a unidades neurona, de manera aleatoria. El perceptrón logró reconocer todas las letras del alfabeto[55].

Las redes neuronales se fundamentan en la generalización de información extraída a partir de datos experimentales o bases de datos. Dichas redes neuronales toman en consideración las entradas y como salidas las señales del sistema[51]. En la figura 2.13 se presenta un diagrama de red neural.

El entrenamiento de la red se basa en el algoritmo que lleva por nombre "retropropagación del error" por el método de descenso por gradiente, en el cual los pesos de la red se actualizan a través del uso de un conjunto ordenado de entradas y salidas deseadas y la comparación entre dicha salida y la salida real de la red neural. También se utiliza para el entrenamiento otra metodología alterna que es el "perceptrón"[51]. Es un clasificador de forma binaria: sólo existe la posibilidad de ser parte de un grupo A o B; funciona con sistemas lineales.

En la sección 2.6 se expone con más detalle el algoritmo de Redes Neuronales.




Figura 2.12: Esquema de la red neuronal multicapas 10-10-5. Entradas (4A). Capa de entradas (4B), capa oculta (4C) y capa de salidas (4D). Salidas (4E). Pesos entre cada neurona (4F) están representados por un punto negro (4G). Fuente: Ponce P. *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega, 2010

## ALGORITMOS GENÉTICOS

Un algoritmo genético (AG) es una técnica de búsqueda iterativa inspirada en los principios de selección natural. Los AG no buscan modelar la evolución biológica sino derivar estrategias de optimización. El concepto se basa en la generación de poblaciones de individuos mediante la reproducción de los padres [51].

J. D. Bagley en 1967 tuvo la siguiente idea: “El funcionamiento de los sistemas adaptables empleando algoritmos genéticos y correlativos”, sin embargo, J. H. Holland, es considerado como el pionero de los AG [51]. En general, los problemas de optimización se proponen de la siguiente manera:

$$x_0 \in X \text{ tal que } f \text{ es un máximo en } x_0, \text{ donde } f : X \rightarrow \mathfrak{R}, \text{ por lo tanto:}$$

$$f(x_0) = \max_{x \in X} f(x)$$

### Definiciones

En la siguiente lista se presentan expresiones diversas que son utilizadas en AG:

Evolución natural	Algoritmo genético
Genotipo	Código de cadena
Fenotipo	Punto sin codificar
Cromosoma	Cadena
Gen	Posición de cadena
Alelo	Valor en una posición determinada
Función de aptitud	valor de la función objetivo

Tabla 2.8: Expresiones utilizadas en la genética y su estructura equivalente. Fuente: [51]

*Genotipo:* La información que se encuentra contenida en el genoma.

*Fenotipo:* Características físicas que posee un organismo, que son atribuidas a la expresión de su fenotipo.

*Cromosoma:* Es la molécula única de ADN.

*Gen:* Herencia de un carácter.

*Alelo:* Valor que posee un gen.

*Función de aptitud:* Función que cuantifica el resultado de una solución.

Las cadenas de los AG son análogas a los cromosomas en el sistema biológico. En los organismos naturales, uno o más cromosomas se combinan para formar la prescripción genética total, para la construcción y operación del organismo. En los organismos naturales el “paquete total” de genética se denomina genotipo. En los AG el “paquete total” de las cadenas se llama estructura (la estructura está compuesta por varias cadenas). En los organismos naturales, la creación de los organismos se realiza mediante la interacción de “paquetes” genéticos con su medio y se llama fenotipo[51].

Los componentes de un algoritmo genético son:

- Una función que desea optimizar.
- Un grupo de candidatos para la solución.
- Una función de evaluación que mida cómo los candidatos optimizan la función
- Función de reproducción.

## 2.5. Algoritmos KNN y Naive Bayes, Redes Neuronales

### 2.5.1. k-Nearest Neighbour

KNN, también conocido como k-nearest neighbour, es un algoritmo de aprendizaje de clasificación de patrones supervisado que nos ayuda a encontrar a qué clase pertenece la nueva entrada (valor de prueba) cuando se eligen  $k$  vecinos más cercanos y se calcula la distancia entre ellos [53].

En KNN, cada uno de los datos de entrenamiento consta de un conjunto de vectores y cada vector tiene su propia etiqueta de clase positiva o negativa, donde  $k$  representa el número de vecinos. Además, la precisión del algoritmo KNN puede verse gravemente degradada por la presencia de:

- i* Datos ruidosos
- ii* Características irrelevantes
- iii* Falta de coherencia de las escalas de características con su importancia

La idea básica es la que se muestra en la Figura 2.14, que muestra un clasificador de “3-Nearest Neighbour” en un problema de dos clases en un espacio de características bidimensional. En este ejemplo, la decisión para  $q_1$  es sencilla: los tres vecinos más cercanos son de clase  $O$ , por lo que se clasifica como  $O$ . La situación para  $q_2$  es un poco más complicada ya que tiene dos vecinos de clase  $X$  y uno de clase  $O$ . Esto puede resolverse mediante votación por mayoría simple o mediante votación ponderada a distancia.

La retropropagación del error es un entrenamiento supervisado que se emplea para redes multicapa, donde se ajusta el valor de los pesos en función del error generado. Es común utilizar esta técnica, ya que permite optimizar el gradiente del error y, en consecuencia, minimizarlo con respecto a los parámetros de la red neuronal.

Como en el caso del perceptrón simple, el MLP fundamenta el proceso de aprendizaje en las contribuciones de sus pesos mediante una norma de ajuste del error. Esta regla ajusta los pesos de las contribuciones a partir de que las salidas de la red coincidan con las salidas deseadas o se aproximen. El algoritmo de aprendizaje del MLP utiliza el método del gradiente descendiente para configurar los pesos de la red. Consiste en dos fases que se repiten hasta conseguir minimizar el error:

- En la primera fase, se aplica un patrón a las entradas de la red y su efecto se propaga a través de la misma, capa a capa. Finalmente, la red presenta un conjunto de salidas como respuesta a dicho patrón de entrada.
- En la siguiente fase, los pesos de la red se recalculan de acuerdo con una regla de ajuste del error. Esto es, se calcula el valor de la función de error que compara la respuesta actual de la red y la respuesta deseada, y este error se propaga hacia atrás [55].

Para explicar este último paso con más detalle se asumirá como función de error el Error Cuadrado Medio (ECM). Así, para cada patrón  $\mathbf{x}_n$  se tiene la siguiente función de error:

$$E^n = \frac{1}{2} \sum_{k=0}^C (e_k^n)^2 \quad (2.62)$$

donde el factor  $1/2$ , que no altera el resultado de la función, se introduce para facilitar los cálculos posteriores, y el error  $e_k^n$  se define como:

$$e_k^n = y_k^n - t_k^n \quad (2.63)$$

Si se supone que nos encontramos en la iteración  $n$  del algoritmo de aprendizaje en el que se ha introducido un patrón  $\mathbf{x}_n$ . El algoritmo de retropropagación corrige el peso sináptico  $w_{kj}$

añadiéndole un incremento  $\Delta w_{kj}$ . En este caso, el incremento es proporcional al gradiente  $\partial E / \partial w_{kj}$  dado que, si consideramos la superficie de error que se forma al representar  $E$  junto el espacio de pesos, este gradiente determina la dirección de la búsqueda en este espacio para obtener el valor del peso  $w_{kj}$  que conduce a un mínimo de  $E$ [55].




Figura 2.32: Ejemplo de descenso gradiente en una red con únicamente 2 pesos. Las flechas indican direcciones en el espacio de búsqueda suponiendo distintos valores iniciales para los pesos  $w_1$  y  $w_2$ . El punto (1) conduce a un mínimo global mientras que los puntos (2) conducen a mínimos locales. Fuente: Palma JT, Marín R. *Inteligencia artificial: Técnicas, métodos y aplicaciones*. McGraw Hill, 2008

La Figura 2.25 muestra un ejemplo sencillo en el que la red sólo tiene dos pesos. Se observa que siguiendo la dirección indicada por el gradiente se conseguirá minimizar el error aunque no siempre se podrá alcanzar el resultado óptimo[55]. De acuerdo con la regla de la cadena para derivadas parciales, este gradiente se representa como:

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial a_k} \frac{\partial a_k}{\partial w_{kj}} = -e_k \tilde{g}'(a_k) z_j \quad (2.64)$$

que se obtiene tras derivar las ecuaciones (2.42), (2.43), (2.44) y  $a_k = \sum_{j=0}^M w_{kj} z_j$  con respecto a las variables indicadas, esto es

$$\frac{\partial E}{\partial e_k} = e_k \quad \frac{\partial e_k}{\partial y_k} = -1 \quad \frac{\partial y_k}{\partial a_k} = \tilde{g}'(a_k) \quad \frac{\partial a_k}{\partial w_{kj}} = z_j \quad (2.65)$$

Teniendo en cuenta que el *gradiente local*  $\delta$  de una neurona  $k$  se define como:

$$\delta_k = \frac{\partial E}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial a_k} = -e_k \tilde{g}'(a_k) \quad (2.66)$$

se tiene que el incremento que se debe aplicar al peso  $w_{kj}$  es:

$$\Delta w_{kj} = \eta \frac{\partial E}{\partial w_{kj}} = \eta \delta_k z_j \quad (2.67)$$

donde  $\eta$  es el ratio de aprendizaje. Esta ecuación señala que, para obtener el incremento necesario, únicamente es necesario multiplicar el valor de  $\delta$  para la unidad de salida de la neurona por el valor  $z$  de la unidad de entrada de la neurona[55].

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**  
**2.5. ALGORITMOS KNN Y NAIVE BAYES, REDES NEURONALES**

---

Para el calculo del gradiente local  $\delta_k$  considerando que la neurona  $k$  puede encontrarse en la capa de salida o en una capa oculta. El primer caso se reduce a calcular el error  $e_k$  aplicando la ecuación (2.44). Sin embargo, si la neurona  $k$  se encuentra en la capa oculta no hay una forma directa de calcular el error, ya que no se conoce la salida deseada en ese punto. Así, este error tendrá que determinarse recursivamente considerando todas las neuronas de la capa de salida a las que está conectada dicha neurona  $k$ [55]. Se denomina  $j$  a la neurona de la capa oculta de la que se desea estimar el gradiente, y  $k$  a cada una de las neuronas de salida. El gradiente local  $\delta_j$  para una neurona en la capa oculta se define como:

$$\delta_j = -\frac{\partial E}{\partial z_j} \frac{\partial z_j}{\partial a_j} = -\frac{\partial E}{\partial z_j} g'(a_j) \quad (2.68)$$

De nuevo se emplea la regla de la cadena para calcular la primera derivada parcial:

$$\frac{\partial E}{\partial z_j} = \sum_k e_k \frac{\partial e_k}{\partial a_k} = \sum_k e_k \frac{\partial e_k}{\partial a_k} \frac{\partial a_k}{\partial z_j} = \sum_k e_k \tilde{g}'(a_k) w_{kj} = -\sum_k \delta_k w_{kj} \quad (2.69)$$

por tanto, retomando la ecuación (2.49):

$$\delta_j = g'(a_j) \sum_k \delta_k w_{kj} \quad (2.70)$$

y el ajuste del peso  $w_{ji}$ , de modo similar a la ecuación (2.48), viene dado por:

$$\Delta w_{ji} = \eta \delta_j x_i \quad (2.71)$$

El error que se ha calculado es el error cometido al introducir el patrón  $n$  éximo, es decir, es un error individualizado. Por ello, los pesos se actualizan cada vez que se le presenta un nuevo patrón  $\mathbf{x}^n$  a la red. Este modo de aprendizaje se conoce como aprendizaje estocástico. Otra opción existente consiste en calcular las derivadas una vez que se han proporcionado a la red todos los patrones (aprendizaje por lotes o *batch*), de este modo los pesos de la primera capa se actualizarían como:

$$\Delta w_{ji} = -\eta \sum_n \delta_j^n x_i^n \quad (2.72)$$

con expresiones análogas para los pesos de la segunda capa.

### Redes Neuronales de Convolución (CNN)

Hay dos arquitecturas de redes neuronales comunes: las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN)[61]. Las CNN se utilizan principalmente para reconocer patrones visuales. Los RNN están diseñados para reconocer patrones en series de tiempo compuestas por símbolos o formas de onda de audio/voz. Tanto las CNN como las RNN son tipos especiales de redes neuronales multicapa. Están entrenadas con el algoritmo de retropropagación[61, 62].

#### Introducción

La clasificación de imágenes, se puede definir como la tarea de categorizar imágenes en una de varias clases anteriormente ya definidas. Constituye la base para otras tareas de visión por computadora, como la localización, detección y segmentación. Las CNN se han convertido en la arquitectura líder para la mayoría de las tareas de reconocimiento, clasificación y detección de imágenes [63].

CNN es una forma especial de la red neuronal de retroalimentación (FNN, feed-forward neural network), también conocida como perceptrón multicapa (MLP), entrenada con retropropagación (backpropagation). Se demostró que las FNN son capaces de aproximar cualquier función medible a la precisión deseada [62].

#### Arquitectura de una CNN

Las CNN son redes de retroalimentación, es decir que el flujo de información va en una sola dirección, que va desde sus entradas hasta sus salidas.

Las arquitecturas de CNN, en general, consisten en capas convolucionales (convolutional layers) y de agrupación (pooling layers), una o más capas completamente conectadas (fully connected layers). La Figura 2.26 ilustra la arquitectura tradicional de CNN para una tarea de clasificación de imágenes. Se introduce una imagen directamente en la red, y a esto le siguen varias etapas de convolución y agrupación. A partir de entonces, las representaciones de estas operaciones alimentan una o más capas completamente conectadas. Finalmente, la última capa completamente conectada genera la etiqueta de clase[?, 63].

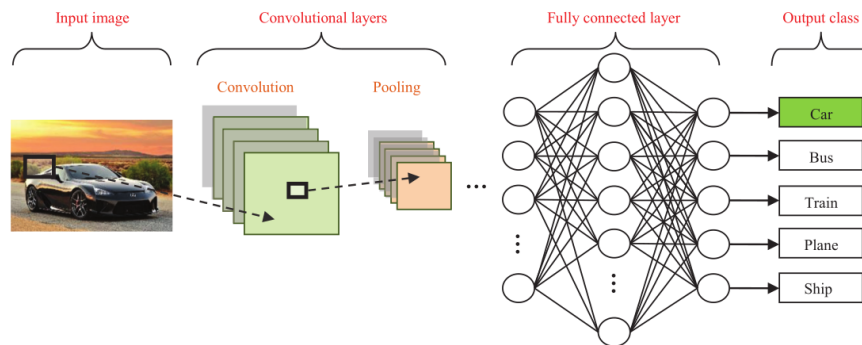


Figura 2.33: Canalización de clasificación de imágenes de CNN. Fuente: Rawat W, Wang Z *Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review*. Neural Computation, 2017.

Una CNN generalmente toma un tensor de orden 3 como entrada, por ejemplo, una imagen con  $H$  filas,  $W$  columnas y 3 canales (canales de color R, G, B). La entrada luego pasa secuencialmente

por una serie de procesamiento. Un paso de procesamiento generalmente se denomina capa, que podría ser una capa anteriormente mencionada.

Una descripción abstracta de la estructura de CNN:

$$\mathbf{x}^1 \rightarrow \boxed{\mathbf{w}^1} \rightarrow \mathbf{x}^2 \dots \rightarrow \mathbf{x}^{L-1} \rightarrow \boxed{\mathbf{w}^{L-1}} \rightarrow \mathbf{x}^L \rightarrow \boxed{\mathbf{w}^L} \rightarrow z \quad (2.73)$$

La Ecuación 2.54 ilustra cómo una CNN se ejecuta capa por capa en una pasada hacia adelante. La entrada es  $\mathbf{x}^1$ , generalmente una imagen (tensor de orden 3). Pasa por el procesamiento en la primera capa, que es la primera caja. Denotamos los parámetros involucrados en el procesamiento de la primera capa colectivamente como un tensor  $w_1$ .

La salida de la primera capa es  $\mathbf{x}^2$ , que también actúa como entrada para el procesamiento de la segunda capa. Este procesamiento continúa hasta que se han terminado todas las capas de la CNN, lo que genera  $\mathbf{x}^L$ . Sin embargo, se agrega una capa adicional para la propagación de errores hacia atrás, un método que aprende buenos valores de parámetros en la CNN. La última capa es una capa de pérdida. En un problema de clasificación, a menudo se utiliza la pérdida de entropía cruzada[66].

### Capas convolucionales (Convolutional layers).

Las capas convolucionales sirven como extractores de características y, por lo tanto, aprenden las representaciones de características de sus imágenes de entrada[63]. Las neuronas de las capas convolucionales se organizan en mapas de características. Cada neurona en un mapa de características tiene un campo receptivo, que está conectado a una vecindad de neuronas en la capa anterior a través de un conjunto de pesos entrenables, a veces denominado banco de filtros. Las entradas se convolucionan con los pesos aprendidos para calcular un nuevo mapa de características, y los resultados convolucionados se envían a través de una función de activación no lineal. Todas las neuronas dentro de un mapa de características tienen pesos que están limitados a ser iguales; sin embargo, diferentes mapas de características dentro de la misma capa convolucional tienen diferentes pesos, por lo que se pueden extraer varias características en cada ubicación[63]. Más formalmente, el  $k$ -ésimo mapa de características de salida  $Y_k$  se puede calcular como:

$$Y_k = f(W_k * x) \quad (2.74)$$

donde la imagen de entrada se denota por  $x$ ; el filtro convolucional relacionado con el  $k$ -ésimo mapa de características se indica mediante  $W_k$ ; el signo de multiplicación en este contexto se refiere al operador convolucional 2D, que se utiliza para calcular el producto interno del modelo de filtro en cada ubicación de la imagen de entrada; y  $f(\cdot)$  representa la función de activación no lineal[63]. Las funciones de activación no lineal permiten la extracción de características no lineales. Tradicionalmente, se utilizaron las funciones de tangente sigmoidea e hiperbólica; recientemente rectificadores lineales unitarios [63, 64].

Por ejemplo, un filtro típico en una primera capa de una red convolucional puede tener un tamaño de  $5 \times 5 \times 3$  (es decir, 5 píxeles de ancho y alto, y 3 porque las imágenes tienen profundidad 3, los canales de color). Durante el pase hacia adelante, deslizamos (más precisamente, convolvemos) cada filtro a lo ancho y alto del volumen de entrada y calculamos los productos escalares entre las entradas del filtro y la entrada en cualquier posición (figura 2.27). A medida que deslizamos el filtro sobre el ancho y la altura del volumen de entrada, produciremos un mapa de características bidimensional que da las respuestas de ese filtro en cada posición espacial. De manera intuitiva, la red aprenderá filtros que se activan cuando ven algún tipo de característica visual, como un borde de alguna orientación o una mancha de algún color en la primera capa, o eventualmente patrones

enteros en forma de panal o rueda en capas superiores de la red.

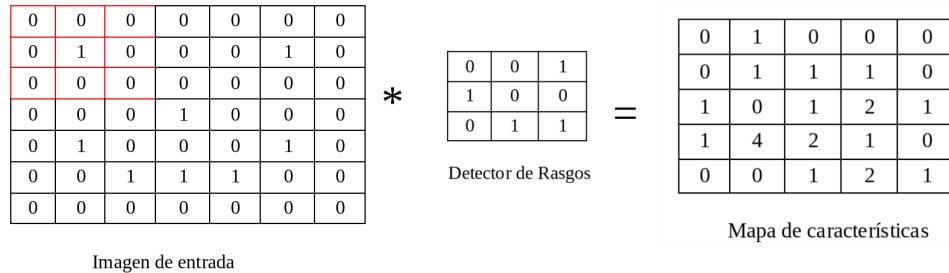


Figura 2.34: Ejemplo de detector de rasgos(filtro).

Disposición espacial.

Para saber cuántas neuronas hay en el volumen de salida o cómo están organizadas, debemos conocer tres hiperparámetros que controlan el tamaño del volumen de salida: la profundidad (depth), el paso (stride) y el relleno de ceros (zero-padding).

1. La profundidad del volumen de salida es un hiperparámetro: corresponde a la cantidad de filtros que nos gustaría usar, cada uno aprendiendo a buscar algo diferente en la entrada. Por ejemplo, si la primera capa convolucional toma como entrada la imagen sin procesar, entonces diferentes neuronas a lo largo de la dimensión de profundidad pueden activarse en presencia de varios bordes orientados o manchas de color.
2. El paso con el que deslizamos el filtro. Cuando la zancada es 1, movemos los filtros un píxel a la vez. Cuando la zancada es 2, los filtros saltan 2 píxeles a la vez a medida que los deslizamos. Esto producirá volúmenes de salida más pequeños espacialmente.
3. A veces será conveniente rellenar el volumen de entrada con ceros alrededor del borde. El tamaño de este relleno de ceros es un hiperparámetro. La buena característica del relleno de cero es que nos permitirá controlar el tamaño espacial de los volúmenes de salida.

Podemos calcular el tamaño espacial del volumen de salida en función del tamaño del volumen de entrada ( $W$ ), el tamaño del campo receptivo de las neuronas de la capa convolucional ( $F$ ), el paso con el que se aplican ( $S$ ) y la cantidad de relleno de cero utilizado ( $P$ ) en el borde. La fórmula correcta para calcular cuántas neuronas “encajan” viene dada por  $(WF + 2P)/S + 1$ .

### Capa ReLU

Las CNN intentan aprender la relación entre la entrada y la salida y almacenan la experiencia aprendida en sus pesos de filtro. Un desafío para comprender las CNN es el papel que desempeña la unidad de activación no lineal después de la operación convolucional.

Las CNN suelen utilizar tres funciones de activación. Son la función sigmoideal, la unidad lineal rectificadora (ReLU) y la ReLU parametrizada (PReLU) como se muestra en la Fig. 2.28 La PReLU también se conoce como ReLU con fugas.

La sigmoideal recorta la entrada en un intervalo entre 0 y 1. El ReLU recorta los valores negativos a cero mientras mantiene los valores positivos sin cambios. El ReLU con fugas tiene un papel similar al ReLU, pero asigna valores negativos más grandes a valores más pequeños al

reducir la pendiente de la función de mapeo.




Figura 2.35: Funciones de activacion. Fuente: Jay Kuo *Understanding Convolutional Neural Networks with A Mathematical Model*. Department of Electrical Engineering, University of Southern California, 2016.

El propósito de ReLU es aumentar la no linealidad de la CNN. Dado que la información semántica en una imagen (por ejemplo, una persona y un perro Husky sentados uno al lado del otro en un banco en un jardín) es obviamente un mapeo altamente no lineal de valores de píxeles en la entrada, queremos que el mapeo de la entrada de CNN a su salida también sea altamente no lineal. La función ReLU, aunque simple, es una función no lineal, como se ilustra en la Figura 2.28

La función sigmoideal funciona significativamente peor que ReLU en el aprendizaje de CNN. Una capa sigmoideal hará que la magnitud del gradiente se reduzca significativamente, y después de varias capas sigmoideales, el gradiente desaparecerá (es decir, todos sus componentes estarán cerca de 0). Un gradiente que desaparece hace que el aprendizaje basado en gradientes sea muy difícil.

La introducción de ReLU para reemplazar la sigmoideal es un cambio importante en CNN, que reduce significativamente la dificultad para aprender los parámetros de CNN y mejora su precisión [66].

### Capas de agrupación (Pooling Layers)

El propósito de las capas de agrupación es reducir la resolución espacial de los mapas de características y así lograr la invariancia espacial para las distorsiones de entrada y las traslaciones. Las capas de agrupación de agrupación máxima (max pooling) propagan el valor máximo dentro de un campo receptivo a la siguiente capa[63]. Formalmente, la agrupación máxima selecciona el elemento más grande dentro de cada campo receptivo de manera que:

$$Y_{kij} = \max_{(p,q) \in \mathcal{R}_{ij}} x_{kpq} \quad (2.75)$$

donde la salida de la operación de agrupación, asociada con el  $k$ -ésimo mapa de características, se denota por  $Y_{kij}$ ,  $x_{kpq}$  denota el elemento en la ubicación  $(p, q)$  contenido por la región de agrupación  $ij$ , que incorpora un campo receptivo alrededor de la posición  $(i, j)$ . La Figura 3.29 ilustra la diferencia entre la combinación máxima y la combinación promedio[63].

La forma más común es una capa de agrupación con filtros de tamaño 2x2 aplicados con un paso de 2 muestras descendentes de cada corte de profundidad en la entrada por 2 a lo largo de la anchura y la altura, descartando el 75 % de las activaciones. En este caso, cada operación MAX tomaría un máximo de 4 números (una pequeña región de 2x2 en un segmento de profundidad). La dimensión de profundidad permanece sin cambios.

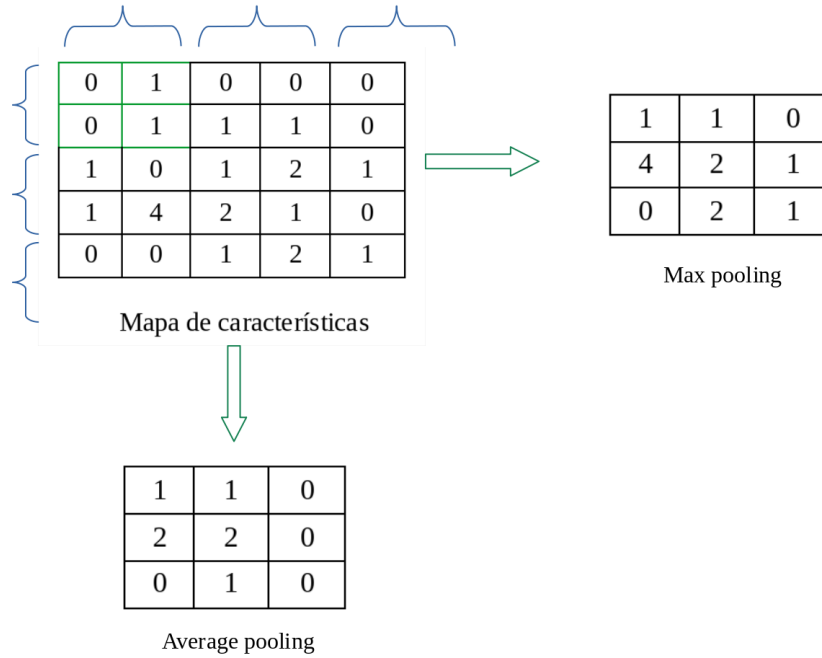


Figura 2.36: Agrupación promedio vs agrupación máxima.

### Capas completamente conectadas (Fully connected layers)

Por lo general, varias capas convolucionales y agrupadas se apilan una encima de la otra para extraer representaciones de características más abstractas al moverse a través de la red. Las capas completamente conectadas que siguen a estas capas interpretan estas representaciones de características y realizan la función de razonamiento de alto nivel[63].

Una capa completamente conectada se refiere a una capa si el cálculo de cualquier elemento en la salida  $x^{l+1}$  (o  $y$ ) requiere todos los elementos en la entrada  $x^l$ . A veces, una capa completamente conectada es útil al final de un modelo de CNN profundo. Por ejemplo, si después de muchas capas de convolución, ReLU y agrupación, la salida de la capa actual contiene representaciones distribuidas para la imagen de entrada, queremos usar todas estas características en la capa actual para construir características con más capacidades en el siguiente. Una capa completamente conectada es útil para este propósito[63].

## 2.6. Aplicaciones de redes neuronales a imágenes médicas de obesidad

Las aplicaciones en el campo de la medicina en las que se ocupan las redes neuronales son diversas y múltiples [68, 69, 70] y su uso está creciendo cada vez más. Las RNAs permiten extraer información útil y producir inferencias a partir de los datos disponibles gracias a su capacidad de aprendizaje. Sus propiedades como reconocedores de patrones, permiten combinar las cualidades del razonamiento humano con la lógica precisa y con la gran capacidad de memoria que poseen los computadores. En este sentido, son de gran utilidad en medicina, en específico en la toma de decisiones clínicas, como sistemas de apoyo[67, 68].

Es frecuente en medicina que exista información imprecisa [69], por otro lado los datos médicos son difíciles de ajustar mediante el uso de la estadística debido a que presentan diversos patrones y propiedades. Un ejemplo de ello es la presencia de subjetividad en algunos casos, imprecisiones en la captura de información, el ruido o información que no alberga relación con el principal problema de salud. Precisamente las RNAs son altamente tolerantes a errores, característica que las convierte en una gran apoyo a la hora de tomar decisiones clínicas, minimizando de esta forma la incertidumbre[68]. Así, las RNAs se convierten en valiosas herramientas que pueden ayudar al clínico a tomar decisiones, esto se da principalmente cuando se presentan los siguientes aspectos [67]:

1. Dificultad para la utilización de pruebas complementarias, por su costo, por el riesgo de su aplicación o por su accesibilidad.
2. Elección entre distintas opciones terapéuticas en función del resultado esperado.
3. Predicción de la evolución de cualquier patología a partir de los signos y síntomas manifestados.

En Medicina las RNAs se han aplicado en las siguientes áreas:

1. Diagnóstico: Para la detección de cáncer y patologías cardíacas.
2. Analítica: A través del análisis bioquímico para detectar condiciones patológicas. Se facilitan los análisis de orina, sangre.
3. Imágenes: Lectura e interpretación de radiografías.
4. Farmacología: Desarrollo de medicamentos para el tratamiento del cáncer. Modelado de biomoléculas.

Poseer ayuda informática facilita los procesos de diagnóstico, ya que los computadores lo ejecutan de manera sistemática y exhaustiva, no tiene dependencia de la experiencia o del estado actual del clínico, además que elimina la necesidad de una memoria operacional que sobrepasa la capacidad humana [70].

La siguiente tabla expone artículos sobre el uso de redes neuronales en imágenes médicas. Se describen por el nombre del artículo, la fecha de su publicación y un pequeño resumen. Los títulos de los artículos se dejaron en el idioma con el que fueron publicados.

Tabla 2.9: Artículos científicos

Artículo	Resumen
----------	---------

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.6. APLICACIONES DE REDES NEURONALES A IMÁGENES MÉDICAS DE OBESIDAD

<p>Medical image classification with convolutional neural network. Autores: Qing Li, Weidong Cai, Xiaogang Wang, Yun Zhou, David Dagan Feng y Mei Chen. (2014)</p>	<p>La clasificación de parches de imágenes es una tarea importante en muchas aplicaciones de imágenes médicas diferentes. En este trabajo se diseña una red neuronal convolucional (CNN) personalizada con una capa de convolución superficial para clasificar los parches de imagen pulmonar con enfermedad pulmonar intersticial (EPI).</p>
<p>Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?. Autores: Nima Tajbakhsh, Jae Y. Shin, Suryakanth R. Gurudu, R. Todd Hurst, Christopher B. Kendall, Michael B. Gotway, Jianming Liang. (2016)</p>	<p>En este artículo, buscan responder a la siguiente pregunta central en el contexto del análisis de imágenes médicas: ¿Puede el uso de CNN profundas previamente entrenadas con suficiente ajuste fino eliminar la necesidad de entrenar una CNN profunda desde cero? Para abordar esta pregunta, consideran cuatro aplicaciones distintas de imágenes médicas en tres especialidades (radiología, cardiología y gastroenterología) que involucran clasificación, detección y segmentación de tres modalidades de imágenes diferentes, e investigan cómo el desempeño de las CNN profundas entrenadas desde cero en comparación con el CNN previamente entrenados y afinados en forma de capas.</p>
<p>Convolutional Neural Network for Medical Image Classification using Wavelet Features. Autores: Amin Khattami, Asef Nazari, Amin Beheshti, Thanh Thi Nguyen, Saeid Nahavandi, Jerzy Zieba. (2020)</p>	<p>Este estudio propone un marco basado en el aprendizaje profundo para la clasificación de imágenes médicas utilizando características de wavelet. Se incorporan redes neuronales convolucionales para descubrir patrones latentes informativos y características de un conjunto de imágenes de rayos X pertenecientes a partes del cuerpo humano. Luego, las características se pasan a un clasificador para etiquetar las respectivas imágenes de rayos X.</p>

**CAPÍTULO 2. FUNDAMENTO TEORÍCO**

**2.6. APLICACIONES DE REDES NEURONALES A IMÁGENES MÉDICAS DE OBESIDAD**

<p>Deep convolutional neural network based medical image classification for disease diagnosis. Autores: Samir S. Yadav y Shivajirao M. Jadhav. (2019)</p>	<p>Este artículo investiga cómo aplicar el algoritmo basado en la red neuronal convolucional (CNN) en un conjunto de datos de rayos X de tórax para clasificar la neumonía. Se evalúan tres técnicas mediante experimentos. Se trata de un clasificador de máquina vectorial de soporte lineal con funciones libres de rotación y orientación local, aprendizaje de transferencia en dos modelos de red neuronal convolucional: Grupo de geometría visual, es decir, VGG16 e InceptionV3, y un entrenamiento de red cápsula desde cero. El aumento de datos es un método de preprocesamiento de datos que se aplica a los tres métodos.</p>
<p>Mammogram Classification Using Convolutional Neural Networks. Autores: Henry Zhou, Yuki Zaninovich, Chris Gregory</p>	<p>Exploran la viabilidad de analizar mamografías (imágenes de rayos X de los senos) utilizando un algoritmo de aprendizaje automático de reconocimiento de imágenes para ayudar en la clasificación de anomalías benignas y cancerosas, así como en la detección de anomalías. Concretamente, analizan la eficacia de las redes neuronales convolucionales (CNN) para determinar la existencia de anomalías mamarias en mamografías. Si hay una anomalía, también la clasifica como benigna o maligna.</p>
<p>Predicting Body Mass Index From Structural MRI Brain Images Using a Deep Convolutional Neural Network. Autores: Pál Vakli, Regina J. Deák-Meszlényi, Tibor Auer y Zoltán Vidnyánszky. (2020)</p>	<p>Investigan, si las imágenes cerebrales estructurales y el aprendizaje profundo(DL) pueden usarse para predecir un rasgo físico que es de relevancia clínica significativa: el índice de masa corporal (IMC) del individuo. Demuestran que el IMC individual se puede predecir con precisión utilizando una red neuronal convolucional profunda (CNN) y un solo escaneo cerebral de imágenes de resonancia magnética estructural (MRI) junto con información sobre la edad y el sexo. Los mapas de localización calculados para la CNN destacaron varias estructuras cerebrales que contribuyeron fuertemente a la predicción del IMC, incluido el núcleo caudado y la amígdala. La comparación con los resultados obtenidos a través de un método de segmentación cerebral automática estándar reveló que el enfoque de visualización basado en CNN arrojó evidencia complementaria con respecto a la relación entre la estructura cerebral y el IMC.</p>

<p>Modelo de Redes Neuronales Convolucionales Profundas para la Clasificación de Lesiones en Ecografías Mamarias. Autores: Hugo Chanampe, Silvana Aciar, Martin de la Vega, José Luis Molinari Sotomayor, German Carrascosa, Alejandro Lorefice</p>	<p>El estudio apunta a utilizar técnicas Deep Learning para clasificar distintos tipos de lesiones en ecografías mamarias. Se muestra el estado del arte de las arquitecturas de Deep Learning en la clasificación de imágenes y sus distintas estrategias de entrenamiento. Usando Redes Neuronales Convolucionales Profundas se desarrolló un modelo que permite clasificar diferentes tipos de lesiones.</p>
<p>Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. Autores: Michal Byra, Grzegorz Styczynski, Cezary Szmi-gielski, Piotr Kalinowski, Lukasz Michalowski, Rafal Paluszkiewicz, Bogna Ziarkiewicz-Wróblewska, Krzysztof Zieniewicz, Piotr Sobieraj, Andrzej Nowicki. (2018)</p>	<p>La enfermedad del hígado graso no alcohólico es la anomalía hepática más común. Hasta la fecha, la biopsia hepática es el estándar de referencia para la cuantificación directa de la esteatosis hepática en muestras de tejido hepático. En este artículo proponen un enfoque basado en redes neuronales para la evaluación de la enfermedad del hígado graso no alcohólico en la ecografía.</p>
<p>Convolutional Neural Networks for Electrocardiogram Classification. Autores: Mohamad M. Al Rahhal, Yakoub Bazi, Mansour Al Zuair, Esam Othman y Bilel BenJdira(2018)</p>	<p>En este artículo, proponen un enfoque de aprendizaje por transferencia para la detección y clasificación de arritmias en bases de datos cruzadas de ECG. Este enfoque se basa en una red neuronal convolucional profunda (CNN) previamente entrenada en un dominio auxiliar (llamado ImageNet) con imágenes etiquetadas muy grandes junto con una red adicional compuesta de capas completamente conectadas.</p>

## CAPÍTULO 2. FUNDAMENTO TEORÍCO

### 2.6. APLICACIONES DE REDES NEURONALES A IMÁGENES MÉDICAS DE OBESIDAD

---

Deep Convolutional Neural Networks for Classifying Body Constitution Based on Face Image. Autores: Er-Yang Huan, Gui-Hua Wen, Shi-Jun Zhang, Dan-Yang Li, Yang Hu, Tian-Yuan Chang, Qing Wang y Bing-Lin Huang. (2017)

Este artículo propone un algoritmo de reconocimiento de la constitución corporal basado en una red neuronal convolucional profunda, que puede clasificar los tipos de constitución individuales de acuerdo con las imágenes faciales. El modelo propuesto primero utiliza la red neuronal convolucional para extraer las características de la imagen de la cara y luego combina las características extraídas con las características de color. Finalmente, las características de fusión se ingresan al clasificador Softmax para obtener el resultado de la clasificación.

## Capítulo 3

### Métodos

#### 3.1. Descripción de la población a estudiar.

Se estudiaron las imágenes de 20 pacientes, los cuales pertenecen a niños varones con edades de entre 7 y 9 años. Todos son diestros, sin antecedentes de problemas o desordenes neuronales y capaces de completar un examen de resonancia. Estos niños participaron en el proyecto METCOG y por tanto se sabe que no presentan depresión al momento del estudio, son pacientes pediátricos y no adolescentes (test de Tanner) y provienen de un estrato socioeconómico medio en México. DE los 20 pacientes, 10 son niños con normo peso y 10 con obesidad. Las imágenes de la figura 3.1 fueron extraídas del grupo de entrenamiento y del grupo de prueba, del conjunto de imágenes de niños con normo peso y con obesidad.




Figura 3.1: RM de paciente con obesidad extraída del grupo de prueba, corte axial a la altura de los pulmones y del corazón (izquierda), RM de paciente con normo peso extraída del grupo de prueba, corte axial a la altura de los pulmones y del corazón (derecha).

## 3.2. Hardware usado para estudio.

El hardware utilizado para el desarrollo, entrenamiento y testeo de los modelos fue el siguiente:

### Computadora ASUS Zenbook

- Intel® Core™ i5-7200U CPU @ 2.50GHz × 4
- Mesa Intel® HD Graphics 620 (KBL GT2)
- 8 GiB RAM
- 1 SSD 256 GB

## 3.3. Software usado para estudio.

### 3.3.1. Python

Python es un lenguaje de programación interpretado, interactivo y orientado a objetos. Incorpora módulos, excepciones, tipificación dinámica, tipos de datos dinámicos de muy alto nivel y clases[72].

La principal característica de Python es que posee una sintaxis que facilita la legibilidad del código. Algunas de las principales ventajas para crear redes neuronales en Python son:

- Acceso a la comunidad abierta de desarrolladores más grande del mundo en cuanto a lenguajes de programación se trata.
- Posibilidad de utilizar múltiples librerías gratuitas de Python que permiten acelerar los procesos de desarrollo. Tales como:
  - Librerías para machine learning en TensorFlow de Google.
  - Librerías para deep learning como las de PyTorch de Facebook y Keras.
- Usabilidad multiplataforma: Windows, MacOS, Linux, Unix, entre otras. Además, se puede acceder a paquetes como PyInstaller, los cuales permiten para preparar el código para distintas plataformas.

Teniendo en cuenta que las redes neuronales, son un subconjunto de machine learning y están en el núcleo de los algoritmos de deep learning, el uso de las librerías de Python permitirán un código más claro y reducido[72].

La versión de Python usada en este trabajo es Python 3.8.3

### 3.3.2. TensorFlow

TensorFlow es una biblioteca de software de código abierto para el cálculo numérico de alto rendimiento. Su arquitectura permite una fácil implementación de la computación en una variedad de plataformas (CPU, GPU, TPU) y desde computadoras de escritorio hasta grupos de servidores y dispositivos móviles[71].

Desarrollado originalmente por investigadores e ingenieros del equipo de Google Brain dentro de la organización de inteligencia artificial de Google, viene con un fuerte soporte para el aprendizaje automático y el aprendizaje profundo, y el núcleo de cálculo numérico flexible se usa en muchos otros dominios científicos [71].

### 3.3.3. Keras

Keras es una API de aprendizaje profundo escrita en Python, que se ejecuta sobre la plataforma de aprendizaje automático TensorFlow. Fue desarrollado con un enfoque en permitir una experimentación rápida[74].

Keras es una librería que funciona a nivel de modelo: proporciona bloques modulares sobre los que se pueden desarrollar modelos complejos de aprendizaje profundo [74, 75].

Hay tres formas de crear modelos Keras:

- **Sequential model** El modelo secuencial, que es muy sencillo (una lista simple de capas), pero está limitado a pilas de capas de una sola entrada y una sola salida (como su nombre indica).
- **Functional API** La API funcional, que es una API completa y fácil de usar que admite arquitecturas de modelos arbitrarias.
- **Model subclassing** Subclases de modelos, donde implementas todo desde cero por tu cuenta.

### 3.4. Diseño o Estructura de nuestra Red Neuronal.

Los argumentos que se presentan en esta sección fueron los utilizados para el algoritmo desarrollado. El diseño de la CNN se dividió en dos secciones, la capa de convolución y la capa completamente conectada, cada una de estas con diferentes capas características, bajo la arquitectura de una CNN (Figura 3.2).

Al inicio de la CNN la imagen entra a la capa de convolución, en esta capa la imagen pasa por la primera capa de convolución que funciona como un filtro para la imagen, para posteriormente seguir hacia la primera capa de MaxPooling que es la responsable de reducir la información, obteniendo al final de estas dos capas los datos característicos de cada imagen. Los datos ahora pasan por una capa de aplando, que produce un vector con toda la información característica de la imagen de entrada. Esta información ingresa a la capa completamente conectada y la CNN aprende de los datos para poder dar la clasificación de salida. Para este trabajo la capa de salida tiene dos resultados, que corresponden a los dos grupos de niños, niños con normo peso y niños con obesidad.

En este trabajo se utilizó el mismo algoritmo para la CNN, la modificación fue en la estructura de esta, es decir se cambio el número de capas de convolución y el número de capas completamente conectadas, por ejemplo, una estructura de red tenía dos capas de MaxPooling y dos capas completamente conectadas mientras otra estructura tenía dos capas de MaxPooling y tres capas completamente conectadas.

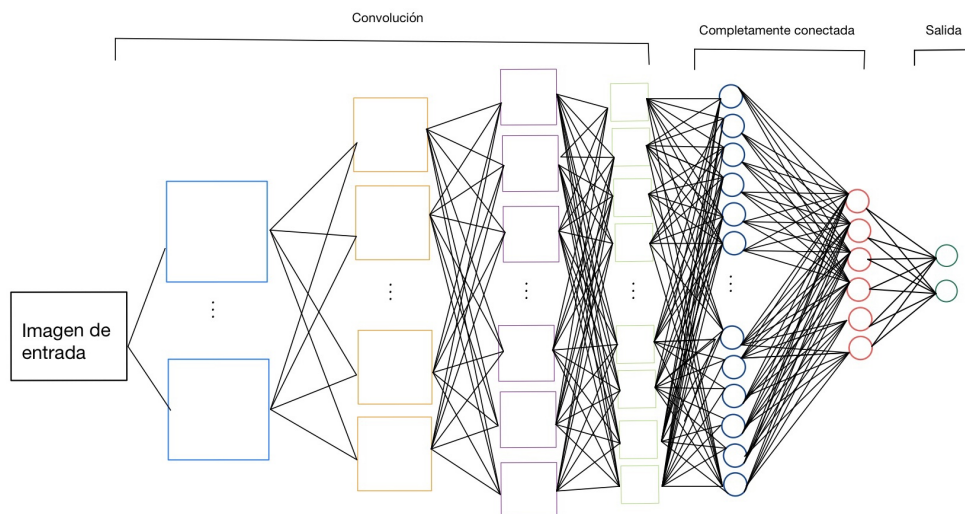


Figura 3.2: Arquitectura usada para CNN. Al inicio de la CNN la imagen entra a la capa de convolución para la extracción de los datos característicos de la imagen, y al salir entra a la capa completamente conectada, donde la red realiza el proceso de aprendizaje de los datos, en la salida la red hace la clasificación.

#### 3.4.1 Capa de convolución

Como primera capa se ocupa una capa de convolución, llamada **Conv2D layer**

Esta capa se importa desde `keras.layer`, crea un núcleo de convolución que se convolucionan con la entrada de la capa para producir un tensor de salidas.

Los argumentos de esta capa son: `filters`, `kernel_size`, `strides`, `padding`, `activation`, `input shape`.

De los cuales, para el propósito de este trabajo se ocuparon los siguientes:

- **filters**: entero, la dimensionalidad del espacio de salida.
- **kernel\_size**: un número entero o tupla / lista de 2 enteros, que especifica la altura y el ancho de la ventana de convolución 2D.
- **activation**: Función de activación a utilizar.
- **Input shape** Tensor 4 + D con forma: `batch_shape + (canales, filas, columnas)`.

Como segunda capa, se uso una capa de agrupación maxima, llamada **MaxPooling2D layer**

Reduce la representación de entrada tomando el valor máximo sobre la ventana definida por `pool_size` para cada dimensión a lo largo del eje de características. La ventana se desplaza por pasos(`strides`) en cada dimensión. La salida resultante cuando se usa la opción de relleno “válida” tiene una forma (número de filas o columnas) de:  $\text{output\_shape} = (\text{input\_shape} - \text{pool\_size} + 1) / \text{strides}$

Los argumentos de esta capa son: `pool_size`, `strides`, `padding`. Los que se ocuparon son:

- **pool\_size**: entero o tupla de 2 enteros, tamaño de ventana sobre el cual tomar el máximo.  $(2, 2)$  tomará el valor máximo en una ventana de agrupación de  $2 \times 2$ .
- **strides**: entero, tupla de 2 enteros o ninguno. Especifica qué tan lejos se mueve la ventana de agrupación para cada paso de agrupación.

Ambas capas se repitieron para poder comparar los resultados de la red dependiendo el número de veces que se añadieron, por ejemplo con dos capas de convolución y dos de maxpooling tenemos la estructura que muestra la figura 3.3, que nos ayuda a obtener información mas específica de la imagen pero con el riesgo de perder información entre las capas.




Figura 3.3: Arquitectura de red con 2 capas de convolución y MaxPooling

Para poder apreciar de una forma más clara lo que hacen estas capas veamos lo siguiente. Las capas de convolución extraen la información más relevante para cada una de las imágenes por medio de los filtros. Estas características van a depender de los valores que tengan los filtros en cada una de sus entradas, esto se puede ver con más claridad en la figura 3.4 y 3.5. En la figura 3.4 se muestra un filtro, donde la matriz de la izquierda nos da los valores del filtro entre 0 y 1 y la matriz de la derecha es una representación de esos valores en escala de grises. En la figura 3.5 se muestran los 16 primeros filtros de una capa de convolución. Como se puede apreciar los filtros van a extraer información diferente y específica en cada una de sus entradas, pues al hacer la

convolución con la imagen de entrada estos actuarán de forma diferente en la imagen, ya sea para resaltar o atenuar ciertos parametros de la imagen, para poder obtener características específicas de ella, tal como se ve en la figura 3.6. Las imágenes de la figura 3.6 son el resultado de pasar la imagen de entrada por los primeros 16 filtros de la primera capa de convolución.




Figura 3.4: Izquierda: valores de filtro normalizado, derecha: filtro representado en escala de grises




Figura 3.5: Primeros 16 Filtros de una capa de convolución representados en escala de grises




Figura 3.6: Izquierda: Imagen de entrada del conjunto de entrenamiento. Derecha: Imagen de entrada al pasarla por los primeros 16 filtros de la primera capa convolucional. Cada filtro extrae información específica de la imagen

Aplicar más de una capa de convolución a la imagen nos puede ayudar a extraer información más específica de una imagen, aunado a esto, aplicar más de una capa de convolución en conjunto una capa de MaxPooling, nos ayudará a obtener información general de la imagen. Eso lo podemos apreciar en la figura 3.7, las imágenes se obtuvieron al pasar la imagen de entrada por dos capas de convolución. Se puede apreciar que el tamaño de la matriz cambia, esto es debido a la capa de MaxPooling que reduce una parte de la información proveniente de la capa de convolución, esto lo hace agrupando los resultados de la convolución.




Figura 3.7: Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la segunda capa convolucional.




Figura 3.8: Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la tercera capa convolucional.

En las figuras 3.8 y 3.9 se pueden apreciar el efecto de pasar la imagen de entrada por una tercera y cuarta capa de convolución y MaxPooling (respectivamente). El tamaño de las matrices

disminuye y cada una de estas matrices tiene características más generales de la imagen de entrada.




Figura 3.9: Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la cuarta capa convolucional.

### 3.4.2 Aplanado

Lo que sigue para poder continuar con la clasificación, es aplanar lo que se obtuvo con las capas anteriores, para eso se uso una capa de aplanado llamada **Flatten layer**. Esta capa aplanada la entrada.

La cual tiene el siguiente argumento:

- **data\_format**: una cadena, uno de `channels_last` (predeterminado) o `channels_first`. El orden de las dimensiones en las entradas.

Uniendo las capas descritas anteriormente tenemos la estructura que muestra la figura 3.10.

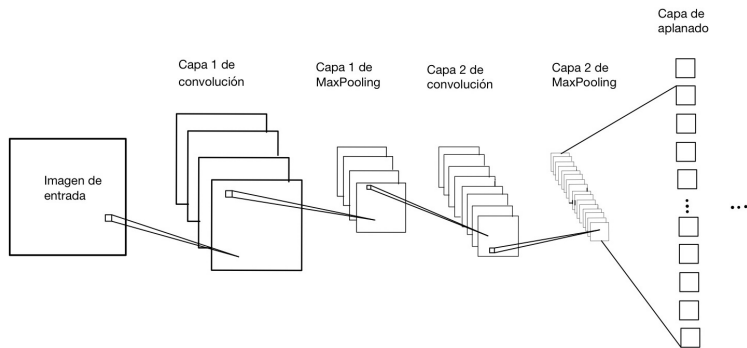


Figura 3.10: Arquitectura de red con 2 capas de convolución, MaxPooling y la capa de aplanado

### 3.4.3 Capa completamente conectada (Full Connection)

Esta es la segunda parte de la red, en esta capa la red aprende de los datos que llegan para realizar la clasificación.

Tiene los siguientes argumentos:

`Dense layer` implementa la operación:  $output = activation(dot(input, kernel) + bias)$  donde `activation` es la función de activación por elementos que se pasa como argumento de activación, el `kernel` es una matriz de pesos creada por la capa y `bias` es un vector de sesgo creado por capa.

Esta capa se repitió para poder comparar los resultados de la red dependiendo del número de capas que se añadieron, esto con el fin de crear mas conexiones entre las capas y con eso poder tener una mayor amplitud de características a considerar al momento de hacer la clasificación, es decir se ocupo más de una capa completamente conectada, por ejemplo con dos capas completamente conectadas y una capa de salida tenemos lo que muestra la figura 3.11, que nos ayuda a tener mas conexiones y evitar la pérdida de información específica.

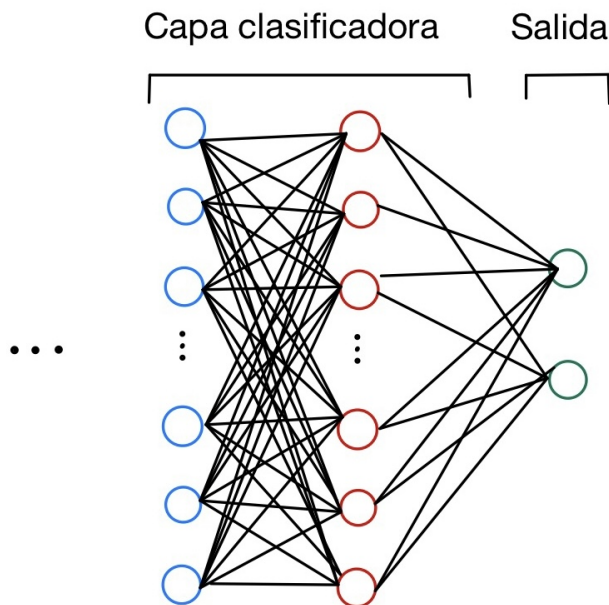


Figura 3.11: Arquitectura de red con 2 capas completamente conectadas y la capa de salida.

### 3.4.4 Compilación

Con la CNN hecha, se configura el modelo para el entrenamiento, en esta parte se le dice a la red el procedimiento a seguir para su aprendizaje.

Los argumentos de este apartado son:

- **optimizer** (optimizador): Cadena (nombre del optimizador) o instancia del optimizador.
- **loss**: Cadena, función objetivo o instancia `tf.keras.losses.Loss`. Devuelve un tensor flotante de pérdida ponderada. El valor de pérdida que será minimizado por el modelo será la suma de todas las pérdidas individuales.
- **metrics** (métricas): lista de métricas que el modelo evaluará durante el entrenamiento y las pruebas.

### 3.4.5 Ajuste de la CNN a las imágenes para entrenar: Image data preprocessing

Lo siguiente fue ajustar la CNN diseñada a las imágenes del grupo de entrenamiento. Para esto de `keras.preprocessing.image` se importa `ImageDataGenerator` el cual tiene los siguientes argumentos:

- **rescale**: factor de cambio de escala.
- **shear\_range**: flotante. Intensidad de corte (ángulo de corte en sentido antihorario en grados)
- **zoom\_range**: flotante. Rango para zoom aleatorio.
- **horizontal\_flip**: booleano. Voltea las entradas de forma aleatoria horizontalmente.

Una vez ajustadas las imágenes de entrenamiento, se ajustaron las imágenes de prueba.

### 3.4.6 Salida de la red

Al terminar los ajustes de las imágenes, comienza la clasificación de estas, comenzando con las imágenes de entrenamiento. El número de veces que las imágenes de entrenamiento pasen por la red neuronal está dado por el número epoch, este número implica el número de ciclos completos del conjunto de imágenes de entrenamiento. Una vez entrenada la red llegará el momento de la clasificación de las imágenes de prueba. En la salida se obtiene la clasificación de cada una de las imágenes de prueba en divididas en dos grupos niños con normopeso y con obesidad. Se obtiene además la precisión y las pérdidas de los conjuntos de entrenamiento y de prueba. La precisión representa el porcentaje de aciertos que tiene la red, es la razón entre el número de acierto y el número total de clasificaciones hechas por la red. Las pérdidas representan la diferencia que existe entre la salida obtenida con la salida deseada, es decir, representan los errores de la salida obtenidos por la red.

### 3.4.7 Imágenes para el entrenamiento

Inicialmente las imágenes estaban en formato DICOM. DICOM es un protocolo estándar de comunicación entre sistemas de información y a la vez un formato de almacenamiento de imágenes médicas (ver Apéndice B). Para poder utilizar estas imágenes como entradas para la CNN, fue necesario cambiar su formato a el formato jpg. Una vez realizado lo anterior, fueron divididas en dos grupos, el grupo de entrenamiento (training set) y el grupo de prueba (testing set), a su vez esta dos carpetas están divididas en dos, que son imágenes de niños con normopeso y con obesidad. A continuación se presenta un esquema (figura 3.12) de lo anterior mencionado.

La imágenes que se ocuparon para el entrenamiento de la red fueron 15439 y 4224 imágenes fueron usadas para la prueba.

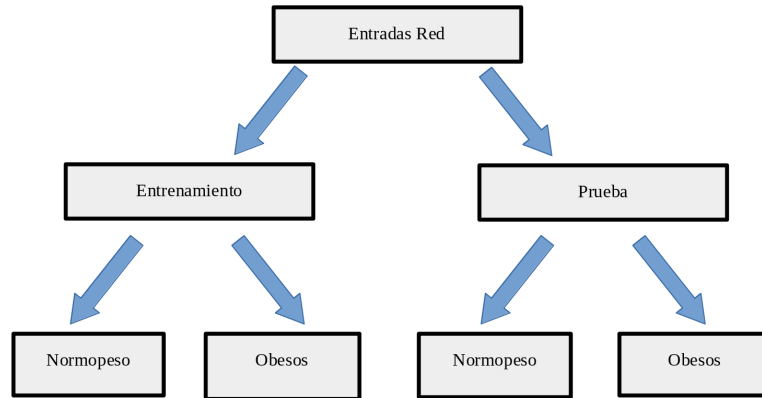


Figura 3.12: División de las imágenes de entrada de la Red Neuronal

### 3.5. Estadística.

El optimizador usado en la red neuronal es el Optimizador que implementa el algoritmo de Adam.

La optimización de Adam es un método de descenso de gradiente estocástico que se basa en la estimación adaptativa de momentos de primer y segundo orden. [74]

El método calcula las tasas de aprendizaje adaptativo individuales para diferentes parámetros a partir de estimaciones del primer y segundo momento de los gradientes; el nombre Adam se deriva de la estimación del momento adaptativo.

Es un algoritmo para la optimización basada en gradientes de primer orden de funciones objetivas estocásticas, basado en estimaciones adaptativas de momentos de orden inferior. Es computacionalmente eficiente, tiene pocos requisitos de memoria, es invariante al cambio de escala diagonal de los gradientes y es adecuado para problemas que son grandes en términos de datos y / o parámetros. Los resultados empíricos demuestran que Adam funciona bien en la práctica y se compara favorablemente con otros métodos de optimización estocástica.[76].

#### 3.5.1. Aspectos básicos

Polyak propuso para el proceso de optimización de primer orden una secuencia  $w_0, w_1, \dots, w_n$ , tal que

$$\omega_{t+1} = \omega_t - \alpha_t \nabla_{\omega_t} f \quad (3.1)$$

hasta que

$$|\omega_{t+1} - \omega_t| \leq \varepsilon_t \quad (3.2)$$

Cuando  $f$  es convexa, la ecuación (3.1) converge en (3.2). Por analogía, observemos que en las aproximaciones de primer orden por diferencia finita en el método de Euler, el parámetro  $\alpha_t$  corresponde con el número de Courant y  $-\nabla_{\omega_t} f$  al sentido contrario del gradiente, lo cual le da el nombre al método de una forma natural. En la inteligencia artificial el parámetro  $\alpha_t$  corresponde

al factor de aprendizaje.

La idea es mejorar el método de descenso rápido como el de momento clásico introduciendo el parámetro para controlar o modificar los movimientos de zig-zag [77].

$$\omega_{t+1} = \omega_t + \nu_{t+1} \tag{3.3}$$

$$\nu_{t+1} = \mu\nu_t - \alpha_t \nabla_{\omega_t} f \tag{3.4}$$

Y una actualización del gradiente por Nesterov genera el método de gradiente acelerado [77]

$$\nu_{t+1} = \mu\nu_t - \alpha_t \nabla_{\omega_t + \mu\nu_t} f \tag{3.5}$$

El método Adam es un método de dos momentos adaptivos en el campo de la optimización estocástica propuesto por los autores Diederik P. Kingma de OpenAI y Jimmy Lei Ba de University of Toronto, pero también se puede usar en la optimización determinista.

Los valores sugeridos por los autores son  $\alpha_t$ ,  $\mu_1$  y  $\mu_2$  como  $10^{-3}$ , 0,9, y 0,999, respectivamente.

En el artículo “ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION” [76] los autores explican de forma detallada y concisa la implementación de este, también analizan las propiedades teóricas de convergencia del algoritmo y proporcionan un límite de pesar en la tasa de convergencia. Finalmente, discuten AdaMax, una variante de Adam basada en la norma del infinito.

A continuación se presenta el algoritmo propuesto en el artículo mencionado

---

**Algorithm 1:** *Adam*, our proposed algorithm for stochastic optimization. See section 2 for details, and for a slightly more efficient (but less clear) order of computation.  $g_t^2$  indicates the elementwise square  $g_t \odot g_t$ . Good default settings for the tested machine learning problems are  $\alpha = 0.001$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$  and  $\epsilon = 10^{-8}$ . All operations on vectors are element-wise. With  $\beta_1^t$  and  $\beta_2^t$  we denote  $\beta_1$  and  $\beta_2$  to the power  $t$ .

---

**Require:**  $\alpha$ : Stepsize  
**Require:**  $\beta_1, \beta_2 \in [0, 1)$ : Exponential decay rates for the moment estimates  
**Require:**  $f(\theta)$ : Stochastic objective function with parameters  $\theta$   
**Require:**  $\theta_0$ : Initial parameter vector  
 $m_0 \leftarrow 0$  (Initialize 1<sup>st</sup> moment vector)  
 $v_0 \leftarrow 0$  (Initialize 2<sup>nd</sup> moment vector)  
 $t \leftarrow 0$  (Initialize timestep)  
**while**  $\theta_t$  not converged **do**  
 $t \leftarrow t + 1$   
 $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$  (Get gradients w.r.t. stochastic objective at timestep  $t$ )  
 $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$  (Update biased first moment estimate)  
 $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$  (Update biased second raw moment estimate)  
 $\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$  (Compute bias-corrected first moment estimate)  
 $\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$  (Compute bias-corrected second raw moment estimate)  
 $\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$  (Update parameters)  
**end while**  
**return**  $\theta_t$  (Resulting parameters)

---

Figura 3.13: Algoritmo Adam de Diederik P. Kingma, Jimmy Lei Ba. ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. ICLR, 2015.

### 3.5.2. Precisión

La precisión de la CNN es el número de clasificaciones correctas sobre el número total de clasificaciones hechas.

La forma de calcularlo es con base a la imagen de entrada. Una vez que la imagen entra a la CNN, se observa como es clasificada por la CNN y si coincide con la clasificación que debería de tener esa imagen, entonces se contabiliza ese aprendizaje, ya que la CNN habría acertado, si por el contrario no coincide la clasificación se tendría un aprendizaje fallido. Al final tendremos el total de aciertos entre el número total de clasificaciones que la CNN realizó.

Este número se puede ver afectado por un sobre ajuste de la CNN. Para comprender esto tenemos que conocer el término de Loss (pérdidas) este concepto mide el error entre la salida obtenida por la CNN con respecto a la salida deseada. Este error es la diferencia entre la salida predicha y la salida deseada.

Normalmente cuando se tiene una red neuronal y comienza su entrenamiento, las pérdidas de la red irán disminuyendo mientras que la precisión va aumentando, pero puede ocurrir que la precisión se mantenga en un valor constante pero las pérdidas tengan un aumento y esto puede deberse a un sobreajuste que se puede erradicar aumentando el número de patrones y / o reducir el número de capas completamente conectadas.



## Capítulo 4

# Resultados

En este trabajo se utilizó el mismo algoritmo para la CNN, lo que se cambió es la estructura de esta, es decir el número de capas de convolución y MaxPooling y el número de capas completamente conectadas. El algoritmo descrito en el apéndice A es la estructura de red con el que se obtuvo la mayor precisión.

Según los parámetros elegidos para el proceso de clasificación las cuales fueron 25 epochs elegidas, donde cada epoch duró entre 1867 y 3122 segundos de la GPU. El proceso de ajuste se realizó con una tasa de aprendizaje muy pequeña y el optimizador Adam ayudó a minimizar la función de pérdida.

La siguiente tabla describe la estructura usada de la CNN y las precisiones obtenidas en el conjunto de entrenamiento y el conjunto de prueba en los primeros 5 epochs.

Capas		Precisión	
Convolución y Maxpooling	Totalmente conectada	Entrenamiento	Prueba
2	2	97.17 %	92.40 %
2	2	99.38 %	93.78 %
2	2	99.63 %	91.50 %
2	2	99.69 %	91.91 %
2	2	99.75 %	88.43 %
2	3	96.77 %	92.07 %
2	3	99.27 %	92.71 %
2	3	99.60 %	87.26 %
2	3	99.70 %	91.57 %
2	3	99.77 %	89.49 %

## CAPÍTULO 4. RESULTADOS

2	4	96.96 %	90.03 %
2	4	99.38 %	94.55 %
2	4	99.65 %	95.00 %
2	4	99.75 %	95.55 %
2	4	99.84 %	92.92 %
3	2	94.52 %	91.60 %
3	2	98.11 %	93.49 %
3	2	98.58 %	92.81 %
3	2	98.90 %	94.03 %
3	2	98.85 %	91.29 %
3	3	95.11 %	92.68 %
3	3	98.39 %	92.48 %
3	3	98.87 %	98.82 %
3	3	99.06 %	90.20 %
3	3	99.11 %	94.39 %
3	4	95.27 %	94.41 %
3	4	98.61 %	94.39 %
3	4	99.05 %	93.23 %
3	4	99.29 %	92.52 %
3	4	99.33 %	92.09 %
4	1	89.81 %	92.45 %
4	1	89.08 %	91.30 %
4	1	84.10 %	73.06 %
4	1	58.80 %	50.00 %
4	1	52.79 %	50.00 %

CAPÍTULO 4. RESULTADOS

4	1	52.59 %	50.00 %
4	2	79.36 %	76.73 %
4	2	53.41 %	50.00 %
4	2	54.87 %	67.40 %
4	2	53.52 %	50.00 %
4	2	56.15 %	80.61 %
4	3	87.91 %	93.18 %
4	3	89.09 %	73.91 %
4	3	89.26 %	90.95 %
4	3	89.26 %	88.82 %
4	3	86.96 %	72.13 %
4	4	87.66 %	88,72 %
4	4	91.07 %	90.88 %
4	4	82.90 %	84.55 %
4	4	88.56 %	87.91 %
4	4	90.18 %	85.76 %

Tabla 4.1: Desempeño de los modelos en los conjuntos de entrenamiento y prueba.

Como se observa en la tabla 4.1 la precisión en el conjunto de prueba puede cambiar considerablemente con elegir un número distinto de capas ya sean de convolución o capas totalmente conectadas. Con estos cambios se busca reducir el tiempo de computo de la red, teniendo en cuenta obtener una mayor precisión en el conjunto de prueba. La tabla 4.2 nos muestra el tiempo promedio por epoch de cada estructura de red usada.

## CAPÍTULO 4. RESULTADOS

---

Capas Convolución/MaxPooling- Completamente Conectadas	Tiempo promedio por Epoch
2-2	2624.6 s
2-3	1966.8 s
2-4	1844.1 s
3-2	1935.9 s
3-3	1885.5 s
3-4	1782.2 s
4-1	1889.5 s
4-2	1934.6 s
4-3	1920.6 s
4-4	2986.5 s

Tabla 4.2: Tiempo de computo de cada estructura de red por epoch

Las figuras 4.1 y 4.2 muestran las pérdidas y precisiones para la estructura de red neuronal con dos y cuatro, cuatro y una capas de convolución y MaxPooling y capas totalmente conectadas (respectivamente). Se muestran las pérdidas y las precisiones de esas estructuras de red a manera de ejemplo. Las pérdidas representan los errores entre la salida obtenida por el sistema contra la salida deseada, es decir calcula la diferencia entre la salida predicha y la salida deseada, la precisión es la cantidad de aciertos entre el total de clasificaciones hechas por la red.

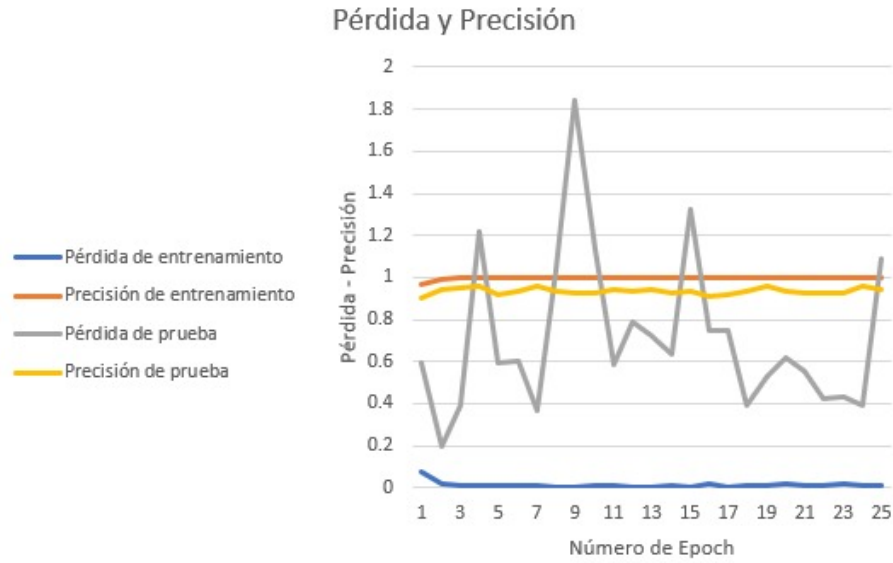


Figura 4.1: Pérdidas y precisiones para una red neuronal con dos capas de convolución y MaxPooling y cuatro capas totalmente conectadas

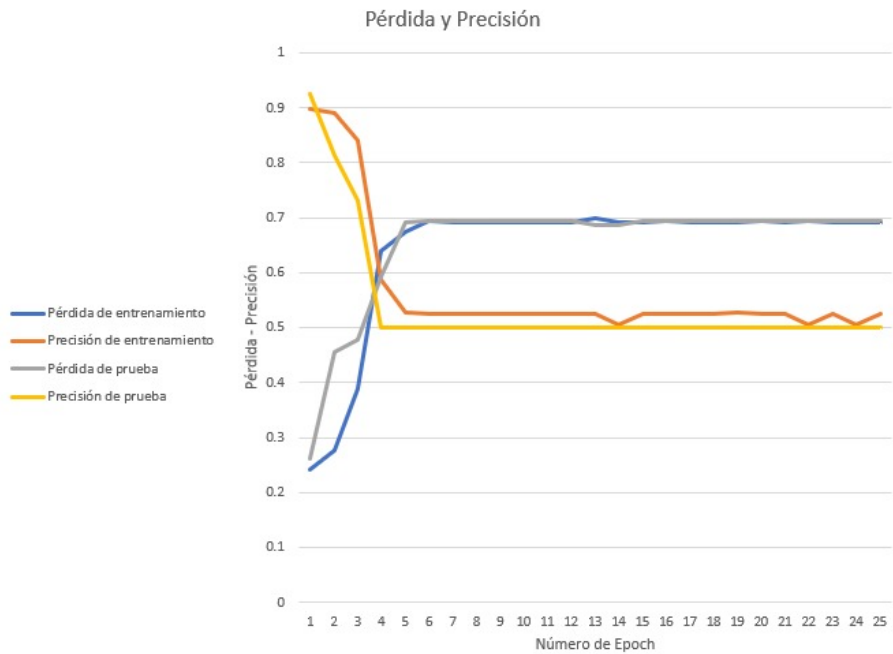


Figura 4.2: Pérdidas y precisiones para una red neuronal con cuatro capas de convolución y MaxPooling y una capa totalmente conectadas



## Capítulo 5

# Discusión y Conclusiones

En este trabajo se utilizó una red neuronal convolucional para la clasificación de imágenes de resonancia magnética de cuerpo entero de 20 pacientes, obteniendo una precisión de red mayor al 95 %. La tabla 4.1 de la sección anterior nos plantea la necesidad de buscar la estructura de red adecuada para un determinado número de imágenes, esto con el fin de lograr una mejora en la precisión del conjunto de entrenamiento.

Considerando las precisiones obtenidas por la red podemos notar que en algunas estructuras de la CNN podría existir un sobreajuste en el conjunto de entrenamiento, específicamente en la estructura de la red que tiene 2 capas de convolución y max pooling con las 2 capas totalmente conectadas, ya que la precisión en el conjunto de entrenamiento llega a superar el 99.5 % cuando la precisión en el conjunto de prueba no pasa del 90 %

Los resultados obtenidos con la configuración de red de 4 capas de Convolución y MaxPooling y 1 capa completamente conectada, nos indican que la CNN obtiene un porcentaje de precisión no satisfactorio, esto podría deberse a la cantidad de información que se está perdiendo, ya que al tener un número considerable de capas de convolución y max pooling en comparación con la única capa totalmente conectada, la información que llega a la red puede no ser lo suficientemente precisa para que la red haga las relaciones necesarias para la clasificación adecuada de las imágenes. La figura 4.2 nos muestra la pérdida y la precisión para el conjunto de entrenamiento y el conjunto de prueba, se puede notar que la precisión de ambos conjuntos se estanca cerca del 50 % y por esa razón las pérdidas, que nos dicen la diferencia entre la salida predicha con la deseada se mantiene constante, indicándonos que no hay una disminución del error.

Esto mismo podemos observarlo con la configuración de red de 4 capas de Convolución y MaxPooling y 2 capas completamente conectadas, las conexiones que hace la CNN no logran obtener una buena precisión en ninguno de los dos conjuntos.

Continuando con la estructura de red que tiene 4 capas de Convolución y MaxPooling, se puede observar que la red obtiene una mejora en las estructuras que siguen, que, apesar de tener más capas totalmente conectadas (las cuales podrían hacer las conexiones que se necesitaban anteriormente) no se obtuvo la precisión conseguida con las primeras estructuras de red, esto nos indica que la red con esa estructura puede estar sobreentrenada.

Los resultados que obtiene la red neuronal con la estructura de 2-3, 2-4, 3-2 (capas de convolución y max pooling y capas totalmente conectadas, respectivamente), son los más precisos, y estas estructuras podrían ser las adecuadas para los conjuntos de imágenes utilizados. La figura 4.1 nos muestra una posible mejora de este trabajo, que es ocupar un conjunto de

## CAPÍTULO 5. DISCUSIÓN Y CONCLUSIONES

---

validación para poder evitar tantas diferencias entre las salida obtenida con la salida deseada, ya que con esto se prodría verificar la precisión de la red antes de suministrarle las imágenes de prueba.

El uso de redes convolucionales para la clasificación de imagenes médicas puede ayudar al clinico en la toma de desiciones, pero nos obliga a buscar una estructura de red que nos permita tener la presición deseada, considerando también el costo computacional, es decir, diseñar un algoritmo que sea eficiente en terminos del tiempo requerido para el computo.

### **Conclusiones**

El uso de sistemas computacionales nos abre las puertas a muchas posibilidades en el ámbito médico, ya que la red neuronal propuesta en este trabajo puede ser usada para la clasificación de otro tipo de imágenes clínicas.

En cuanto a los objetivos de este trabajo, se logró diseñar una red neuronal capaz de clasificar imágenes de resonancia magnética, capaz de distinguir el grupo de imágenes de cuerpo entero de niños con obesidad del grupo de normopeso.

Las posibles mejoras a este trabajo van de la mano con la cantidad de imágenes que se ocuparon, la estructura de red y el costo computacional. Para una mejor clasificación es necesario aumentar el número de imagenes para el entrenamiento de la red y junto con esto aumentar la cantidad de conexiones que tiene que hacer la CNN para poder tener una buena precisión al hacer la clasificación. Este aumento ocasionaráun aumento en el tiempo que se ocupa para el calculo de cada epoch, es decir habrá un aumento computacional.

# Índice de figuras

2.1.	Un imán clínico de alto campo con cama para el paciente (Izquierda). Los tres componentes principales de un sistema de resonancia magnética, incluido el imán superconductor que produce un fuerte campo magnético ( $B_0$ ) en la dirección horizontal. Solo se muestra una de las tres bobinas de gradiente para mayor claridad (Derecha). Fuente: En <i>Introduction to Medical Imaging Physics, Engineering and Clinical Applications</i> , por N. B. Smith y A. Webb, 2001, por Cambridge University Press. . . . .	12
2.2.	Un núcleo con espín con carga positiva produce un campo magnético conocido como momento magnético orientado en paralelo al eje de rotación (Izquierda). Esta disposición es análoga a una barra magnética en la que se considera que el campo magnético está orientado desde el polo sur hacia el norte (Derecha). Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002. . . . .	13
2.3.	Imágenes subatómicas y macroscópicas de una colección de protones en ausencia de un campo magnético externo. En ausencia de un campo, los protones tienen sus vectores de espín orientados aleatoriamente (imagen subatómica, izquierda). La suma vectorial de estos vectores de espín es cero (imagen macroscópica, derecha). Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002. . . . .	14
2.4.	Dentro de un campo magnético, un protón precesa o alrededor del campo magnético. La dirección de precesión es paralela al campo magnético principal $B_0$ . El componente $z$ del vector de espín (proyección del espín sobre el eje $z$ ) es el componente de interés porque no cambia en magnitud o dirección cuando el protón precesa. Los componentes $x$ e $y$ varían con el tiempo a una frecuencia $\omega_0$ proporcional a $B_0$ como se expresa en la ecuación (2.1). Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002 . . . . .	15
2.5.	Diagrama de Zeeman. En ausencia de un campo magnético (Izquierda), una colección de protones tendrá las configuraciones de componentes $z$ iguales en energía para que no haya una alineación preferencial entre las orientaciones de giro hacia arriba y hacia abajo. En presencia de un campo magnético (Derecha), la orientación de giro hacia arriba (paralela a $B_0$ ) es de menor energía y su configuración contiene más protones que la configuración de giro hacia abajo de mayor energía. La diferencia de energía $\Delta E$ entre los dos niveles es proporcional a $B_0$ . Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002 . . . . .	16
2.6.	La aplicación de un pulso de RF alrededor del eje $x$ hace girar la magnetización desde la dirección $z$ hacia el eje $y$ . Si la intensidad y duración del pulso de RF se eligen para producir un pulso de $90^\circ$ , entonces la magnetización se encuentra directamente a lo largo del eje $y$ (Izquierda). Cuando el pulso de RF se apaga, la magnetización precesa alrededor del eje $z$ a la frecuencia de Larmor $\omega_0$ (Derecha). Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002 . . . . .	17
2.7.	Vector de magnetización después de un pulso de RF de $90^\circ$ alrededor del eje $x$ (Izquierda). La relación $T_1$ y $T_2$ de la magnetización un cierto tiempo después de que se ha aplicado el pulso da como resultado un componente $M_z$ aumentado y un componente $M_y$ reducido, respectivamente (Centro). Después de un tiempo más, los componentes $M_z$ y $M_y$ casi han regresado a sus valores de equilibrio de $M_0$ y cero, respectivamente (Derecha). Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> . Wiley-Liss, 2002 . . . . .	18

---

2.8.	La recuperación de la magnetización $M_z$ en función del tiempo después de un pulso de $90^\circ$ para un tejido con tiempo de relajación $T_1$ corto (línea continua) y tiempo de relajación $T_1$ largo (línea discontinua). Cuando $t = 5 * T_1$ , $M_z \sim 99\% M_0$ , que se supone que es una recuperación completa . . . . .	19
2.9.	Para un rango dado (ancho de banda) de frecuencias incluidas en el pulso de RF, el grosor de corte deseado está determinado por la amplitud del gradiente de selección de corte. La interfaz de usuario normalmente permite la variación del grosor del corte, que se logra aumentando o disminuyendo la amplitud del gradiente de selección del corte, según corresponda. Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> .Wiley-Liss, 2002 . . . . .	21
2.10.	Proceso de selección de cortes. En presencia de un gradiente ( $G_{SS}$ ), el campo magnético total que experimenta un protón y su frecuencia resonante resultante dependen de su posición, según la Ecuación 3.15. El tejido ubicado en la posición $z_i$ absorberá la energía de radiofrecuencia transmitida con una frecuencia central $\omega_i$ . Cada posición tendrá una frecuencia de resonancia única. El grosor de corte $\Delta z$ está determinado por la amplitud de $G_{SS}$ y por el ancho de banda de las frecuencias transmitidas $\Delta w$ . Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> .Wiley-Liss, 2002 . . . . .	21
2.11.	Imágenes en direcciones de corte estándar: sagital, coronal y transversal o axial. Para imágenes transversales, son posibles dos direcciones de visualización: craneal y caudal. Fuente: Brown MA y Semelka RC. <i>MRI Basic Principles and Applications</i> .Wiley-Liss, 2002 . . . . .	22
2.12.	Esquema de la red neural multicapas 10-10-5. Entradas (4A). Capa de entradas (4B), capa oculta (4C) y capa de salidas (4D). Salidas (4E). Pesos entre cada neurona (4F) están representados por un punto negro (4G). Fuente: Ponce P. <i>Inteligencia artificial con aplicaciones a la ingeniería</i> . Alfaomega, 2010 . . . . .	28
2.32.	Ejemplo de descenso gradiente en una red con únicamente 2 pesos. Las flechas indican direcciones en el espacio de búsqueda suponiendo distintos valores iniciales para los pesos $w_1$ y $w_2$ . El punto (1) conduce a un mínimo global mientras que los puntos (2) conducen a mínimos locales. Fuente: Palma JT, Marín R. <i>Inteligencia artificial: Técnicas, métodos y aplicaciones</i> . McGraw Hill, 2008 . . . . .	31
2.33.	Canalización de clasificación de imágenes de CNN. Fuente: Rawat W, Wang Z <i>Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review</i> . Neural Computation, 2017. . . . .	33
2.34.	Ejemplo de detector de rasgos(filtro). . . . .	35
2.35.	Funciones de activacion. Fuente: Jay Kuo <i>Understanding Convolutional Neural Networks with A Mathematical Model</i> . Department of Electrical Engineering, University of Southern California, 2016. . . . .	36
2.36.	Agrupación promedio vs agrupación máxima. . . . .	37
3.1.	RM de paciente con obesidad extraída del grupo de prueba,corte axial la altura de los pulmones y del corazón (izquierda), RM de paciente con normo peso extraída del grupo de prueba, corte axial a la altura de los pulmones y del corazón (derecha). . . . .	43
3.2.	Arquitectura usada para CNN. Al inicio de la CNN la imagen entra a la capa de convolución para la extracción de los datos característicos de la imagen, y al salir entra a la capa completamente conectada, donde la red realiza el proceso de aprendizaje de los datos, en la salida la red hace la clasificación. . . . .	46
3.3.	Arquitectura de red con 2 capas de convolución y MaxPooling . . . . .	47
3.4.	Izquierda: valores de filtro normalizado, derecha: filtro representado en escala de grises . . . . .	48
3.5.	Primeros 16 Filtros de una capa de convolución representados en escala de grises . . . . .	48
3.6.	Izquierda: Imagen de entrada del conjunto de entrenamiento. Derecha: Imagen de entrada al pasarla por los primeros 16 filtros de la primera capa convolucional. Cada filtro extrae información específica de la imagen . . . . .	48
3.7.	Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la segunda capa convolucional. . . . .	49
3.8.	Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la tercera capa convolucional. . . . .	49
3.9.	Imagen del conjunto de entrenamiento al pasarla por primeros 16 filtros de la cuarta capa convolucional. . . . .	50
3.10.	Arquitectura de red con 2 capas de convolución, MaxPooling y la capa de aplanado . . . . .	50
3.11.	Arquitectura de red con 2 capas completamente conectadas y la capa de salida. . . . .	51
3.12.	División de las imágenes de entrada de la Red Neuronal . . . . .	53
3.13.	Algoritmo Adam de Diederik P. Kingma, Jimmy Lei Ba. ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. ICLR, 2015. . . . .	54

---

**ÍNDICE DE FIGURAS**  
**ÍNDICE DE FIGURAS**

---

4.1.	Pérdidas y precisiones para una red neuronal con dos capas de convolución y MaxPooling y cuatro capas totalmente conectadas . . . . .	61
4.2.	Pérdidas y precisiones para una red neuronal con cuatro capas de convolución y MaxPooling y una capa totalmente conectadas . . . . .	61
B.1.	Fuente:¿Qué es el formato DICOM?. Clinic Cloud. <a href="https://clinic-cloud.com/blog/formato-dicom-que-es-estandar-imagenes-medicas/">https://clinic-cloud.com/blog/formato-dicom-que-es-estandar-imagenes-medicas/</a> . . . . .	74



# Índice de tablas

2.1.	Clasificación de la obesidad y el sobrepeso según la OMS de acuerdo al IMC y su relación con comorbilidades. Fuente: Obesity and overweight.World Health Organization. <a href="http://www.who.int/whr/2003/en/">http://www.who.int/whr/2003/en/</a> .	7
2.2.	Factores Epidemiológicos asociados al exceso de peso, Fuente: Moreno M. <i>Definition and classification of obesity</i> . [Rev. Med. Clin. Condes - 2012; 23(2) 124-128]	8
2.3.	Comorbilidad y complicaciones de la obesidad, Fuente: Catenacci VA, Hill JO, Wyatt HR. <i>The obesity epidemic</i> . Clin Chest Med 2009;30:415-444.	9
2.4.	Fuente: Adaptado de Ian Mills (Ed.) Quantities, Units, and Symbols in Physical Chemistry, IUPAC, Physical Chemistry Division, Blackwell, Oxford, UK, 1989.	13
2.5.	Tiempos de relajación del tejido a 1.5 y 3 Tesla. Fuente: <i>Introduction to Medical Imaging Physics, Engineering and Clinical Applications</i> , por N. B. Smith y A. Webb, 2001, por Cambridge University Press.	19
2.6.	Algunas definiciones de las IA [51]	24
2.7.	Categorías en que se clasifica la IA. Fuente: [51]	24
2.8.	Expresiones utilizadas en la genética y su estructura equivalente. Fuente: [51]	28
2.9.	Artículos científicos	38
4.1.	Desempeño de los modelos en los conjuntos de entrenamiento y prueba.	59
4.2.	Tiempo de computo de cada estructura de red por epoch	60



## Apéndice A

# Código de la Red Neuronal

Importar las librerías y paquetes

```
from keras.models import Sequential
from keras.layers import Conv2D
from keras.layers import MaxPooling2D
from keras.layers import Flatten
from keras.layers import Dense
```

Inicializar la RNC

```
classifier = Sequential()
```

Capa de Convolución.

```
classifier.add(Conv2D(filters = 64, kernel_size = (3, 3), input_shape = (64, 64, 3), activation = 'relu'))
```

Capa Max Pooling.

```
classifier.add(MaxPooling2D(pool_size = (2,2)))
```

Segunda capa de convolución y max pooling.

```
classifier.add(Conv2D(filters = 32, kernel_size = (3, 3), activation = 'relu'))
classifier.add(MaxPooling2D(pool_size = (2,2)))
```

Capa Flattening

```
classifier.add(Flatten())
```

Capa Full Connection

```
classifier.add(Dense(units = 128, activation = 'relu'))
classifier.add(Dense(units = 64, activation = 'relu'))
classifier.add(Dense(units = 32, activation = 'relu'))
```

## APÉNDICE A. CÓDIGO DE LA RED NEURONAL

---

```
classifier.add(Dense(units = 1, activation = "sigmoid"))
```

Compilar la RNC

```
classifier.compile(optimizer = ".adam", loss = "binary_crossentropy", metrics  
= [".accuracy"])
```

Ajustar la RNC a las imágenes para entrenar

```
from keras.preprocessing.image import ImageDataGenerator  
  
train_datagen = ImageDataGenerator( rescale=1./255, shear_range=0.2,  
zoom_range=0.2, horizontal_flip=True)  
  
test_datagen = ImageDataGenerator(rescale=1./255)  
  
training_dataset = train_datagen.flow_from_directory('dataset/training_set',  
target_size=(64, 64), batch_size=32, class_mode='binary')  
  
testing_dataset = test_datagen.flow_from_directory('dataset/test_set',  
target_size=(64, 64), batch_size=32, class_mode='binary')
```

Clasificador

```
classifier.fit_generator(training_dataset, steps_per_epoch=15439, epochs=25,  
validation_data=testing_dataset, validation_steps=4224)
```

# Apéndice B

## DICOM<sup>®</sup>

DICOM<sup>®</sup> (Digital Imaging and Communications in Medicine): Imágenes digitales y comunicaciones en medicina.

Es el estándar internacional para imágenes médicas e información relacionada. Define los formatos de imágenes médicas que se pueden intercambiar con los datos y la calidad necesarios para el uso clínico[78].

Se implementa en casi todos los dispositivos de radiología, cardiología y radioterapia (rayos X, CT, MRI, ultrasonido, etc.) y cada vez más en dispositivos en otros dominios médicos como la oftalmología y la odontología. Con cientos de miles de dispositivos de imágenes médicas en uso, DICOM<sup>®</sup> es uno de los estándares de mensajería de atención médica más ampliamente implementados en el mundo. Hay literalmente miles de millones de imágenes DICOM<sup>®</sup> actualmente en uso para la atención clínica[78].

Desde su primera publicación en 1993, DICOM<sup>®</sup> ha revolucionado la práctica de la radiología, permitiendo el reemplazo de la película de rayos X con un flujo de trabajo totalmente digital. Así como Internet se ha convertido en la plataforma para nuevas aplicaciones de información para el consumidor, DICOM<sup>®</sup> ha habilitado aplicaciones avanzadas de imágenes médicas que han “cambiado el rostro de la medicina clínica”. Desde el departamento de emergencias hasta las pruebas de esfuerzo cardíaco y la detección del cáncer de mama, DICOM<sup>®</sup> es el estándar que hace que las imágenes médicas funcionen, tanto para médicos como para pacientes[78].

DICOM<sup>®</sup> está reconocido por la Organización Internacional de Normalización como el estándar ISO 12052.

### **Campo de aplicación**

El estándar DICOM pertenece al campo de la informática médica. Dentro de ese campo, aborda el intercambio de información digital entre equipos de imágenes médicas y otros sistemas. Debido a que dicho equipo puede interoperar con otros dispositivos médicos y sistemas de información, el alcance de este estándar debe superponerse con otras áreas de la informática médica. Sin embargo, el estándar DICOM no aborda la amplitud de este campo.

Este estándar ha sido desarrollado con énfasis en las imágenes médicas de diagnóstico que se practican en radiología, cardiología, patología, odontología, oftalmología y disciplinas afines, y terapias basadas en imágenes como radiología intervencionista, radioterapia y cirugía. a una amplia gama de información relacionada con imágenes y no relacionada con imágenes que se




Figura B.1: Fuente:¿Qué es el formato DICOM?. Clinic Cloud. <https://clinic-cloud.com/blog/formato-dicom-que-es-estandar-imagenes-medicas/>

intercambia en entornos clínicos, de investigación, veterinarios y otros entornos médicos.

Este estándar facilita la interoperabilidad de sistemas que afirman conformidad en un entorno de múltiples proveedores, pero no garantiza, por sí mismo, la interoperabilidad.

# Bibliografía

- [1] Raymundo Paredes Sierra. *Sobrepeso y Obesidad en el Niño y el Adolescente*. Seminario sobre Medicina y Salud, 2007.
- [2] Manuel Moreno . *DEFINICIÓN Y CLASIFICACIÓN DE LA OBESIDAD* . Revista Médica Clínica Las Condes, 2012.
- [3] Organización Mundial de la Salud: Obesidad y Sobrepeso,  
<https://www.who.int/es/news-room/fact-sheets/detail/obesity-and-overweight>
- [4] Octavio Amancio, José Ortigoza, e Irene Durante. *Obesidad* . Seminario sobre Medicina y Salud, 2007.
- [5] Ximana Ortega, Gonzalo Corral, Gonzalo Rojas. *Resonancia magnética de cuerpo completo para estudio muscular y cuantificación de fracción grasa. en pacientes pediátricos con mipatías hereditarias*. REV. MED. CLIN. CONDES, 2018.
- [6] Javier Dávila, José González, y Antonio Barrera. *Panorama de la Obesidad en México*. Revista Médica del Instituto Mexicano del Seguro Social, 2015.
- [7] Juan Ángel Rivera Dommarco, M. Arantxa Colchero, Mario Luis Fuentes, Teresita González de Cosío Martínez, Carlos A. Aguilar Salinas, Gonzalo Hernández Licona y Simón Barquera *La obesidad en México Estado de la política pública y recomendaciones para su prevención y control*. Instituto Nacional de Salud Pública, 2018.
- [8] NCD Risk Factor Collaboration. *Trends in adult body-mass index in 200 countries from 1975 to 2014: a pooled analysis of 1698 population-based measurement studies with 19.2 million participants*. Lancet, 2016.
- [9] Stevens GA, Singh GM, Lu Y, Danaei G, Lin JK, Finucane MM. *National, regional, and global trends in adult overweight and obesity prevalences..* Popul Health Metr., 2012.
- [10] Shamah-Levy T, Ruiz-Matus C, Rivera-Dommarco J, Kuri-Morales P, Cuevas-Nasu L *Encuesta Nacional de Salud y Nutrición de Medio Camino 2016. Resultados Nacionales..* Instituto Nacional de Salud Pública, 2017.
- [11] Barquera S, Campos I, Rivera JA. *Mexico attempts to tackle obesity: the process, results, push backs and future challenges*. Obes Rev., 2013.
- [12] World Health Organization. *World health statistics 2017: monitoring health for the SDGs, Sustainable Development Goals*. Geneva: World Health Organization, 2017.
- [13] Blanca Delgado, y Jaime Mas. *AVANCES EN EL ESTUDIO EXPERIMENTAL DE LA BIOQUÍMICA HEPÁTICA*. Universidad Nacional Autónoma de México, 2017.

- [14] Stanford Children's Health: Anatomía y función del hígado, <https://www.stanfordchildrens.org/es/topic/default?id=anatomyandfunctionoftheliver-90-P06162>
- [15] Sergio Del Valle Díaz, Marjoris Piñera Martínez, Juan Antonio Sanchez Vega y Jesús Díaz Fondén *Enfermedad hepática por depósito de grasa*. Hospital Provincial Docente Clínicoquirúrgico "Saturnino Lora Torres", Santiago de Cuba, 2015.
- [16] World Gastroenterology Organisation *Guías de la Organización Mundial de Gastroenterología. Enfermedad del hígado graso no alcohólico y esteatohepatitis no alcohólica*. 2012.
- [17] Méndez Sánchez N, Gutiérrez Grobe Y, Chávez Tapia C, Kobashi Margain RA y Uribe M. *Hígado graso no alcohólico y esteatohepatitis no alcohólica: conceptos actuales..* Rev Gastroenterol Méx, 2010.
- [18] Roldan Valadez E, Favila R, Martínez López M, Uribe M y Méndez Sánchez N. *Imaging techniques for assessing hepatic fat content in nonalcoholic fatty liver disease*. Ann Hepatol, 2008.
- [19] Centers for Disease Control and Prevention (CDC), National Center for Health Statistics (NCHS). Third National Health and Nutrition Examination Survey (NHANES III), <http://www.cdc.gov/nchs/nhanes/nh3data.htm>
- [20] Tortora, G. J. y Derrickson B. *Principios de anatomía y fisiología*. Panamericana, 956-976, 2013.
- [21] Diplomado en ultrasonografía: Anatomía del Hígado, <https://diplomadomedico.com/anatomia-del-higado/>
- [22] Raúl Carrillo Esper y Jimena Muciño Bermejo. *Hígado graso y esteatohepatitis no alcohólica*. Revista de la Facultad de Medicina de la UNAM, 2011.
- [23] Ong JP y Younossi ZM. *Epidemiology and Natural History of NAFLD and EHNA*. Clin Liver Dis, 2007.
- [24] Mark Feldman, Lawrence Friedman y Lawrence Brandt *Sleisenger Fordtran's Gastrointestinal and Liver Disease*. Saunders, 2006.
- [25] Trigo, T.F. *Patología sistémica veterinaria*. McGraw Hill interamericana, 109-110, 1998.
- [26] Videla LA, Rodrigo R, Araya J, Poniachik J. *Insulin resistance and oxidative stress interdependency in non-alcoholic fatty liver disease*. Trends Mol Med, 2006.
- [27] Angulo P. *Nonalcoholic fatty liver disease..* N Engl J Med. 2002.
- [28] Farrell GC, Larter CZ. *Nonalcoholic fatty liver disease: from steatosis to cirrhosis..* Hepatology. 2006.
- [29] Browning J., Szczepaniak L., Dobbins R., Nuremberg P., Hortom J., y Cohen J. *Prevalence of hepatic steatosis in an urban population in the United States: impact of ethnicity*. Hepatology, 2004.
- [30] NHS: Non-alcoholic fatty liver disease (NAFLD), <https://www.nhs.uk/conditions/non-alcoholic-fatty-liver-disease/>
- [31] Videla LA, Obregón AM, Pettinelli P. *Pathology of nonalcoholic fatty liver disease (NAFLD) associated with obesity: pathogenetic mechanisms*. Medwave, 2011.

- [32] Víctor Espinoza Román, *El hígado graso en los niños y la obesidad infantil Causas, síntomas y diagnóstico del hígado graso en los niños*, <https://www.guiainfantil.com/salud/obesidad/el-higado-graso-en-los-ninos-y-la-obesidad-infantil/>
- [33] Aronis A, Madar Z, Tirosh O. *Mechanism underlying oxidative stress-mediated lipotoxicity: exposure of J774.2 macrophages to triacylglycerols facilitates mitochondrial reactive oxygen species production and cellular necrosis*. Free Radic Biol Med. 2005
- [34] Jiménez Agüero, R., Emparanza, J.I., Beguiristain, A. et al *Novel equation to determine the hepatic triglyceride concentration in humans by MRI: diagnosis and monitoring of NAFLD in obese patients before and after bariatric surgery*. BMC Med 12, 137 (2014). <https://doi.org/10.1186>
- [35] Videla LA, Rodrigo R, Orellana M, Fernandez V, Tapia G, Quiñones L, Varela N, Contreras J, Lazarte R, Csendes A, Rojas J, Maluenda F, Burdiles P, Diaz JC, Smok G, Thielemann L, Poniachik J. *Oxidative stress-related parameters in the liver of non-alcoholic fatty liver disease patients.. Clin Sci (Lond)*. 2004.
- [36] Elizondo A, Araya J, Rodrigo R, Signorini C, Sgherri C, Comporti M, Poniachik J, Videla LA. *Effects of weight loss on liver and erythrocyte polyunsaturated fatty acid pattern and oxidative stress status in obese patients with non-alcoholic fatty liver disease*. Biol Res. 2008.
- [37] Sies H, Stahl W, Sevanian A. *Nutritional, dietary and postprandial oxidative stress*. J Nutr. 2005.
- [38] Araya J, Rodrigo R, Videla LA, Thielemann L, Orellana M, Pettinelli P, Poniachik J. *Increase in long-chain polyunsaturated fatty acid n - 6/n - 3 ratio in relation to hepatic steatosis in patients with non-alcoholic fatty liver disease.. Clin Sci (Lond)*. 2004.
- [39] Araya J, Rodrigo R, Pettinelli P, Araya AV, Poniachik J, Videla LA. *Decreased liver fatty acid delta-6 and delta-5 desaturase activity in obese patients*. Obesity (Silver Spring). 2010 Jul;18(7):1460-3. Epub 2009 Oct 29.
- [40] Mark A. Brown y Richard C. Semelka. *MRI Basic Principles and Applications*. Wiley-Liss, 2002.
- [41] George J, Liddle C.. *Nonalcoholic fatty liver disease: pathogenesis and potential for nuclear receptors as therapeutic targets*. . Mol Pharm. 2008.
- [42] Evans JL, Maddux BA, Goldfine ID. *The molecular basis for oxidative stress-induced insulin resistance*. Antioxid Redox Signal. 2005.
- [43] Pettinelli P, Del Pozo T, Araya J, Rodrigo R, Araya AV, Smok G, Csendes A, Gutierrez L, Rojas J, Korn O, Maluenda F, Diaz JC, Rencoret G, Braghetto I, Castillo J, Poniachik J, Videla LA. *Enhancement in liver SREBP-1c/PPAR-alpha ratio and steatosis in obese patients: correlations with insulin resistance and n-3 long-chain polyunsaturated fatty acid depletion.. Biochim Biophys Acta*, 2009.
- [44] Schwarz JM, Linfoot P, Dare D, Aghajanian K. *Hepatic de novo lipogenesis in normoinsulinemic and hyperinsulinemic subjects consuming high-fat, low-carbohydrate and low-fat, high-carbohydrate isoenergetic diets*. Am J Clin Nutr. 2003. J Clin Nutr. 2003.
- [45] Donnelly KL, Smith CI, Schwarzenberg SJ, Jessurun J, Boldt MD, Parks EJ *Sources of fatty acids stored in liver and secreted via lipoproteins in patients with nonalcoholic fatty liver disease*. Clin Invest. 2005

- [46] Pettinelli P, Videla LA. *Up-regulation of PPAR-gamma mRNA expression in the liver of obese patients: an additional reinforcing lipogenic mechanism to SREBP-1c induction*. Clin Endocrinol Metab, 2011.
- [47] Videla LA. *Oxidative stress and insulin resistance as interdependent pathogenic mechanisms in non-alcoholic fatty liver disease associated with obesity*. En: *Free Radical Pathophysiology*, Alvarez S.. Transworld Research Network; Kerala, India 2008
- [48] Nadine Barrie Smith y Andrew Webb. *Introduction to Medical Imaging Physics, Engineering and Clinical Applications*. Cambridge University Press, 2001.
- [49] Zepeda, C., Aguilar, J. , Moreno, E. *Proton wave function in a water molecule: Breakdown of degeneration caused by interactions with the magnetic field of a Magnetic Resonance Imaging device*. Medical Physics (physics.med-ph), 2021.
- [50] Bloch F. *Nuclear Induction*. Physical Review, 1946.
- [51] Pedro Ponce Cruz. *INTELIGENCIA ARTIFICIAL CON APLICACIONES A LA INGENIERÍA*. Alfaomega, 2010.
- [52] Kishan Mehrotra, Chilukuri K. Mohan y Sanjay Ranka. *Elements of Artificial Neural Networks*. MIT Press, 1996.
- [53] Pádraig Cunningham y Sarah Jane Delany. *k-Nearest Neighbour Classifiers*. Mult Classif Syst, 2007.
- [54] K. Ming Leung. *Naive Bayesian Classifier*. POLYTECHNIC UNIVERSITY Department of Computer Science, 2007.
- [55] José T. Palma Méndez y Roque Marín Morales *INTELIGENCIA ARTIFICIAL Métodos, técnicas y aplicaciones*. McGraw Hill, 2008.
- [56] Manning, C., Schütze, H. *Foundations of Statistical Natural Language Processing*. The MIT Press, Cambridge 1999.
- [57] Rezaul Begg, Joarder Kamruzzaman y Ruhul Sarker. *Neural Networks in Healthcare: Potential and Challenges*. IDEA GROUP PUBLISHING, 2001.
- [58] R.N. Shepard. *Toward a universal law of generalization for psychological science..* Science, 1987.
- [59] Jörg Walter Schaaf. *Fish and Shrink: A Next Step Towards Efficient Case Retrieval in Large-Scale Case Bases*. In I. Smith and B. Faltings, editors, European Conference on Case-Based Reasoning , 1996.
- [60] A. Beygelzimer, S. Kakade, y J. Langford. *Cover trees for nearest neighbor..* Proceedings of 23rd International Conference on Machine Learning G, 2006.
- [61] Y. LeCun, Y. Bengio, G. E. Hinton. *Deep learning*. Nature, 2015.
- [62] K. Hornik, M. Stinchcombe, H. White *Multilayer feedforward networks are universal approximators*. Neural networks 2, 1989.
- [63] Waseem Rawat y Zenghui Wang *Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review..* Neural Computation, 2017.
- [64] Jay Kuo *Understanding Convolutional Neural Networks with A Mathematical Model*. Department of Electrical Engineering, University of Southern California, 2016.

- [65] CS231n Convolutional Neural Networks for Visual Recognition,  
<https://cs231n.github.io/convolutional-networks/>
- [66] Jianxin Wu *Introduction to Convolutional Neural Networks*. National Key Lab for Novel Software Technology Nanjing University, China, 2017.
- [67] Sáenz N, Ballesteros M. *Redes neuronales: concepto, aplicaciones y utilidad en medicina*.. Centro de Salud Castilla La Nueva Área 9 de Atención Primaria, 2002.
- [68] Trujillano J, March J, Sorribas A. *Aproximación metodológica al uso de redes neuronales artificiales para la predicción de resultados en medicina*. Medicina Clínica, 2004.
- [69] Juan Vega *Aplicación de las Redes Neuronales Artificiales en Medicina*. Revista de Ciencias de la Salud y Medicina, 2016.
- [70] Lugo Reyes S, Maldonado Colín G, Murata Ch *Inteligencia artificial para asistir el diagnóstico clínico en medicina*.. Revista Alergia México, 2014.
- [71] tensorflow 2.4.1,  
<https://pypi.org/project/tensorflow/>
- [72] General Python FAQ,  
<https://docs.python.org/3/faq/general.html#what-is-python>
- [73] Redes neuronales con Python: ¿por qué es el mejor lenguaje para IA?,  
<https://blog.enzymeadvisinggroup.com/redes-neuronales-python>
- [74] Keras API reference,  
<https://keras.io/api/>
- [75] Keras: biblioteca de código abierto para crear redes neuronales,  
<https://www.ionos.mx/digitalguide/online-marketing/marketing-para-motores-de-busqueda/que-es-keras/>
- [76] Diederik P. Kingma, Jimmy Lei Ba. *ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION*. ICLR, 2015.
- [77] Abraham Rojano; Raquel Salazar ; Luis Miranda , Waldo Ojeda. *ALGORITMO ADAM EN LA INTELIGENCIA ARTIFICIAL*. COMEII-21005, 2021.
- [78] DICOM Digital Imaging and Communications in Medicine,  
<https://www.dicomstandard.org/>
- [79] N. Sáenz Bajo, E. Barrios Rueda, M. Conde Gómez, I. Domínguez Macías, A. López Carabáño, C. Méndez Díez. *Use of neurone networks in medicine: concerning dyspeptic pathology*. Atencion Primaria, 2002.