



**DESARROLLO DE UN CLASIFICADOR BASADO EN REDES
NEURONALES PARA LA DETECCIÓN DE ESCOLIOSIS EN IMAGEN RX DE
COLUMNA**

GONZALO ENRIQUE MARTÍNEZ OJEDA

UNIVERSIDAD ANTONIO NARIÑO
FACULTAD DE INGENIERÍA MECÁNICA, ELECTRÓNICA Y BIOMÉDICA
INGENIERÍA BIOMÉDICA
POPAYÁN
2022

**DESARROLLO DE UN CLASIFICADOR BASADO EN REDES
NEURONALES PARA LA DETECCIÓN DE ESCOLIOSIS EN IMAGEN RX DE
COLUMNA**

GONZALO ENRIQUE MARTÍNEZ OJEDA

Trabajo de grado requisito para obtener el título de:

INGENIERO BIOMÉDICO

Director del proyecto

PhD. CESAR AUGUSTO QUINAYÁS BURGOS

Línea de Investigación:

INGENIERÍA DE REHABILITACIÓN

UNIVERSIDAD ANTONIO NARIÑO

FACULTAD DE INGENIERÍA

INGENIERÍA BIOMÉDICA

POPAYÁN

2022

NOTA DE ACEPTACIÓN

FIRMA DEL DIRECTOR

FIRMA DEL JURADO

FIRMA DEL JURADO

Popayán,

CONTENIDO

	Pág.
RESUMEN.....	15
ABSTRACT.....	17
INTRODUCCIÓN	19
1.CAPÍTULO I. PROBLEMA DE INVESTIGACIÓN	21
1.1 PLANTEAMIENTO DEL PROBLEMA	21
1.2 JUSTIFICACIÓN	22
1.3 OBJETIVOS	23
1.3.1 Objetivo general.	23
1.3.2 Objetivos específicos.	23
2.CAPÍTULO 2. ESTADO DEL ARTE	25
2.1 ESTADO DEL ARTE	25
3.CAPÍTULO 3. MARCOS DE REFERENCIA	29
3.1 MARCO TEÓRICO	29
3.1.1 Tipos de escoliosis.	30
3.1.1.1 Escoliosis tipo s.	30
3.1.1.2 Escoliosis tipo C o escoliosis de una curva.	30
3.1.2 Clasificación.	32
3.1.2.1 Primaria o idiopática.	32
3.1.2.2 Secundaria o no idiopática.	33
3.1.3 Pruebas diagnósticas.	34
3.1.3.1 Radiografías.	34
3.1.4 Redes neuronales artificiales.	38

3.1.5	Redes neuronales convolucionales.	41
3.1.6	Partes de una red neuronal convolucional (RNC).	42
3.1.7	Extracción de características.	42
3.1.8	Convolución.	44
3.1.9	Pooling.	46
3.1.10	Activación no-lineal de la red.	47
3.1.10.1	Sigmoide.	48
3.1.10.2	Tangente hiperbólica.	49
3.1.10.3	ReLu.	50
3.1.11	Dropout.	52
3.1.12	Softmax.	52
3.1.13	Capa de salida.	53
3.1.14	Métodos de aprendizaje.	53
3.1.14.1	ADAM	53
3.1.15	Evaluación.	54
3.1.16	Entrenamiento.	55
3.1.17	Kaggle.	57
3.1.18	Validación.	58
3.1.19	Google Colaboratory.	58
4.CAPÍTULO	4. MATERIALES Y MÉTODOS	61
.....		
4.1	MATERIALES	61
4.2	METODOLOGÍA.	61
4.2.1.1	Extracción de imágenes.	61
4.2.1.2	Acondicionamiento.	67
4.2.1.3	Asignación de clases.	70
4.2.2	Estructura de la red convolucional.	70
4.2.2.1	Métodos de clasificación	70
4.2.2.2	Parámetros de compilación.	74
4.2.3	Entrenamiento y validación de la red convolucional.	75
4.2.4	Validación de la red.	76

4.2.4.1 Accuracy.					79
4.2.4.2 Precisión.					81
5.CAPÍTULO	5.	RESULTADOS	Y	DISCUSIONES	
.....					83
6.CAPÍTULO	6.	CONCLUSIONES	Y	RECOMENDACIONES	
.....					85
REFERENCIAS				87

LISTA DE FIGURAS

	Pág.
Figura 3-1. Escoliosis tipo C y tipo S.....	31
Figura 3-11. Convolución sobre la matriz de una imagen.....	45
Figura 3-12. Max Pooling.	47
Figura 3-13.1 Max Pooling aplicada.....	47
Figura 3-14. Función de activación sigmoide.	49
Figura 3-15. Función de activación tangente hiperbólica.	50
Figura 3-16. Función de activación.	51
Figura 3-17. Función de activación ReLu aplicada.	51
Figura 3-18. Dropout.	52
Figura 3-19. Conjunto imágenes de entrenamiento.....	55
Figura 3-20. Base de datos de Kaggle.....	58
Figura 4-1. Estructura de la metodología.	61
Figura 4-2. Imagen Types of Scoliosis.....	62
Figura 4-3. Imagen Hospital Sagrado Corazón de Jesús.	63
Figura 4-4. Imagen de paciente sano.....	64
Figura 4-5. Cuenta de Kaggle.	65
Figura 4-6. Descarga de API.	65
Figura 4-7. Instalación API en Colab.....	66
Figura 4-8. Directorio de Google Drive base de datos.....	66
Figura 4-9. Reasignar y redimensionar.....	68

Figura 4-10. Imágenes redimensionadas.....	68
Figura 4-11. Reasignar y redimensionar.....	69
Figura 4-12. Separación de imágenes.....	69
Figura 4-13. Asignación de clases.	70
Figura 4-14 Maquina de vector soporte.....	72
Figura 4-15. Arquitectura de red convolucional 2 capas.	73
Figura 4-16. Red convolucional 2 capas Google Colab.....	74
Figura 4-17. Parámetros para la compilación de la red.	75
Figura 4-18. Diagrama de entrenamiento.....	75
Figura 4-19. Entrenamiento de la red convolucional.....	76
Figura 4-20. Matriz de confusión.....	77
Figura 5-1. Precisión algoritmo 1.	83
Figura 5-2. Precisión algoritmo 2.	83
Figura 5-3. Épocas_Accuracy.	84

LISTA DE TABLAS

	Pág.
Tabla 2-1. Estado del arte.....	25
Tabla 3-1. Escoliosis tipo C.	32
Tabla 3-2. Escoliosis tipo S.	32
Tabla 4-1. Conjunto de datos.	62
Tabla 4-1. Tabla de confusión.	77
Tabla 4-1. Tabla para obtener los VN.	78
Tabla 4-1. Tabla para obtener los FP.	78
Tabla 4-1. Tabla para obtener los FN.	79

RESUMEN

La medicina ha crecido de una forma considerable con la tecnología en los últimos años, las herramientas como el Machine Learning en el área médica son unas de las más tecnificadas que representan un gran beneficio para la prevención y diagnóstico de patología en pacientes. En este trabajo se implementa en Python una red neuronal convolucional constituida por dos capas de convolución y una red feedforward con 128 neuronas y una capa de salida con tres neuronas para la clasificación de escoliosis tipo C y S y pacientes sanos a partir de imágenes de RX de columna de una base de datos de Kaggle y una base de datos propia obtenida del Hospital Sagrado Corazón de Jesús, con el propósito de que este algoritmo sirva de apoyo a los fisioterapeutas y ortopedistas en la toma de decisiones y que se pueda realizar en un menor tiempo.

Los resultados obtenidos durante el desarrollo de las pruebas indican que la herramienta tiene un grado aceptable de precisión comparada otros artículos como “Development and validation of deep learning algorithms for scoliosis screening using back images” que tiene una precisión superior al 80% utilizando imágenes de pacientes en tiempo real o fotografías que incluyeron un total de 3240 imágenes para el entrenamiento (incluidos 1029 hombres y 2211 mujeres) y para la validación un total de 400 imágenes (300 imágenes con escoliosis y 100 de pacientes sanos), sin embargo el clasificador implementado en este trabajo se entrenó y validó con una muestra limitada de imágenes (150 imágenes, repartidas en 75 imágenes para entrenamiento y 75 imágenes para prueba), obteniendo un porcentaje de acierto del 94%, lo cual se puede constituir en una herramienta de apoyo al diagnóstico del tipo de escoliosis de manera automatizada a diferencia de los métodos convencionales.

Palabras claves: Escoliosis, redes neuronales, imágenes de RX.

ABSTRACT

Medicine has grown considerably with technology in recent years, tools such as Machine Learning in the medical area are some of the most technical that represent a great benefit for the prevention and diagnosis of pathology in patients. In this work, a convolutional neural network consisting of two convolution layers and a feedforward network with 128 neurons and an output layer with three neurons is implemented in Python for the classification of scoliosis type C and S and healthy patients from RX images. of column of a Kaggle database and a proprietary database obtained from the Sagrado Corazón de Jesús Hospital, with the purpose that this algorithm serves as support to physiotherapists and orthopedists in decision making and that it can be carried out in a shorter time.

The results obtained during the development of the tests indicate that the tool has an acceptable degree of accuracy compared to other articles such as "Development and Validation of Deep Learning Algorithms For Scoliosis Screening Using Back Images" Which Has An Accuracy Over 80% Using Back Images. Real-time patients or photographs that included a total of 3240 images for training (including 1029 men and 2211 women) and for validation a total of 400 images (300 images with scoliosis and 100 of healthy patients), however the implemented classifier In this work, a limited sample of images was trained and validated (150 images, divided into 75 images for training and 75 images for testing), obtaining a success rate of 94%, which can be a support tool for the diagnosis of the type of scoliosis in an automated way, unlike conventional methods.

Keywords: Scoliosis, neural networks, X-ray images

INTRODUCCIÓN

El presente trabajo de grado corresponde a la patología de la columna vertebral: escoliosis, la escoliosis congénita es una malformación lateral de la columna con una alteración del perfil sagital causada por malformaciones de vértebras y costillas. Las principales características son alteración de la columna en el plano sagital que es principalmente cifótica debido a deformidades de los cuerpos vertebrales, sin embargo, también son posibles deformidades lordóticas. Esta patología causa una deformidad en S o C de la columna vertebral en su plano coronal y es de las que tiene mayor prevalencia entre las enfermedades de columna.

El objetivo del presente trabajo es entrenar un clasificador basado en redes neuronales convolucionales con una base de datos de imágenes RX de escoliosis, para dar cumplimiento con este objetivo se tendrán que componer un subconjunto de imágenes de escoliosis tipo S y C utilizando una base de datos de Kaggle, para la ejecución de la red neuronal se utilizara Google Colab por su portabilidad y ser de código libre, por su bajo costo computacional, se utilizó una red multicapa (2 capas de convolución), se empleó este esquema por el bajo costo computacional y por ser uno de los mejores clasificadores de imágenes cuando se cuenta con un número limitado de imágenes, para el entrenamiento de la red se utilizó una data set extraído de Kaggle que está compuesto 49 imágenes de Rx de ellas 25 son de pacientes con escoliosis tipo c y 24 pacientes con escoliosis tipo s, adicionalmente se contó con un banco de imágenes para la validación que fueron dadas por el “Hospital Sagrado Corazón de Jesús” de un total de 56 imágenes de pacientes que presentan escoliosis 28 con escoliosis tipo s 28 pacientes con escoliosis tipo c.

CAPÍTULO I. PROBLEMA DE INVESTIGACIÓN

1.1 PLANTEAMIENTO DEL PROBLEMA

La deformación de la columna vertebral es una condición importante en el diagnóstico de pacientes pediátricos, especialmente en adolescentes, y puede ser una conclusión regular en el examen físico de los hábitos (Ramírez y Acevedo, 2018). La escoliosis es una deformación común de la columna vertebral del 2% al 4% de los jóvenes y adultos de 10 a 25 años. La gravedad del progreso es la variable, de los puntos identificados y no se progresa siempre y cuando desarrollen formas progresivas (10%) y/o bajo, que se vinculan usualmente a otras anomalías, especialmente nerviosas (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

La escoliosis es una afección en la que la columna se desvía hacia un lado de la línea media. Aparece como una deformidad compleja caracterizada por curvatura lateral y rotación de la columna. A medida que avanza la deformación, las vértebras y sus apófisis espinosas en la región de la gran curva rotarán hacia la gravedad de la curva. Las vértebras giratorias empujan las costillas laterales convexas para doblarse hacia atrás; Por lo tanto, dan lugar a una joroba lateral y unen las costillas en superficies cóncavas (Campaña, 2020).

La escoliosis en general afecta a aproximadamente al 70% de personas en el mundo entero, aproximadamente 3 de cada 100 personas tienen alguna forma de escoliosis, sin embargo, para muchas de ellas no representa un problema

El diagnóstico de esta patología en Colombia se efectúa a través de manera subjetiva y tardía a causa del poco desarrollo de tecnologías en este ámbito e incipientes investigaciones para la prevención y predicción de enfermedades degenerativas, como lo es

la escoliosis (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

Las técnicas más avanzadas para la detección de escoliosis son los rayos X que permiten la mejor visualización de la curvatura de la columna y no que la valoración dependa de la subjetividad del radiólogo. Existen diferentes técnicas para realizar la medición de escoliosis en una radiográfica, algunas un tanto complejas, las más prácticas que se aplican son las técnicas de Cobb y Ferguson (Villavicencio, 2020; Quispicondor, 2019).

El ángulo se evalúa mediante el método de Cobb identificando las vértebras terminales o periféricas en cada curva, que se definen como aquellas al final de cada curva más cercanas al centro de la curva con la menor rotación. De tal forma que, la vértebra superior de la curva corresponde a la más alta y su superficie superior está orientada hacia la curva. Por otro lado, se utiliza el método de Ferguson, que consiste en medir las curvaturas cuando las láminas terminales de los cuerpos vertebrales no pueden ser identificado fácilmente, como es el caso de la escoliosis congénita (Villavicencio, 2020).

Para tener un diagnóstico temprano y con menor subjetividad para determinar la presencia o no de escoliosis y el tipo de desviación en el presente trabajo se propone la siguiente pregunta de investigación: ¿Cómo determinar el tipo de escoliosis a partir de imágenes RX utilizando un algoritmo de Deep Learning?

1.2 JUSTIFICACIÓN

La temprana detección de deformidades de la columna en pacientes es relevante por la posibilidad de agravarse con el crecimiento y con el tiempo se puede complicar su tratamiento. Aunque estas curvaturas, incluso severas, son toleradas por adolescentes y niños de forma frecuente; su desarrollo puede representar un riesgo significativo para los pacientes

adultos debido a factores agravantes como un aumento del grado de curvatura de la columna (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

Este trabajo integral de grado tiene como propósito desarrollar un algoritmo de clasificación que le permita al personal médico determinar el tipo de escoliosis o desviación de la columna de un paciente.

El diagnóstico de escoliosis a través de imágenes es una herramienta innovadora que permite al médico o fisioterapeuta tener un diagnóstico rápido y seguro para diagnosticar el grado de escoliosis.

1.3 OBJETIVOS

1.3.1 Objetivo general.

Entrenar un clasificador basado en redes neuronales convolucionales con una base de datos de imágenes RX de escoliosis y validar el entrenador con imágenes RX de columna de pacientes de la clínica “Hospital Sagrado Corazón de Jesús” mediante un comité de ética hospitalaria conformado por Técnico de rayos x, especialista en ortopedia, fisioterapeuta.

1.3.2 Objetivos específicos.

- Componer un subconjunto de imágenes de escoliosis para las desviaciones tipo C y S utilizando la base a partir de la base de datos Kaggle que permita extraer imágenes para entrenamiento y validación de la red neuronal convolucional.

- Implementar un algoritmo de clasificación basado en redes neuronales convolucionales en Google Colab para clasificar el tipo de escoliosis presente en imágenes de RX de la base de datos compuesta.

- Validar el algoritmo entrenado utilizando métricas como la exactitud y matriz de confusión utilizando imágenes de RX obtenidas de una muestra de pacientes sanos y pacientes con escoliosis del “Hospital Sagrado Corazón de Jesús”.

CAPÍTULO 2. ESTADO DEL ARTE

2.1 ESTADO DEL ARTE

Se realiza una breve descripción bibliográfica acerca de información relacionada con el tratamiento digital de imágenes de rayos x, sus aplicaciones, y generación de imágenes médicas a partir de simulaciones virtuales, sirviendo como guía para enfocar, delimitar y estructurar la investigación descrita en el siguiente trabajo.

(Tabla 1).

Tabla 2-1. Estado del arte.

Trabajos	Objetivos	Aportes	Brechas
Prevalencia de escoliosis de columna lumbar, en pacientes de 45 a 70 años con rayos x digital, en la clínica cruz blanca de la ciudad de quito, período abril del 2014 a diciembre del 2014 Lisintuña (Molina, 2015).	El objetivo fue determinar la prevalencia de escoliosis lumbar en pacientes de 45 a 70 años, mediante radiografía digital en la Clínica Cruz Blanca de Quito durante el período de mayo-abril de 2014 a diciembre de 2014.	<ul style="list-style-type: none"> • Información detallada de la patología, presentes en imágenes de RAYOS X. • Caracterización de tipos de imágenes. • Uso de técnicas de procesamiento de imágenes aplicando rayos x, clasificando el número de pacientes atendidos según su edad, genero tipo de estudio. 	<ul style="list-style-type: none"> • Se limita solo a clasificación de datos de muestra regional.
Correlación radiográfica entre el método de Cobb y el método de Nash en el diagnóstico de Escoliosis en columna dorso	Determinar la correlación radiográfica entre el método de Cobb y el método de Nash para el diagnóstico de	<ul style="list-style-type: none"> • Es una base para los conceptos introductorios a la escoliosis. 	<ul style="list-style-type: none"> • Los informes radiológicos se evaluaron solo para los pacientes examinados

Trabajos	Objetivos	Aportes	Brechas
lumbar. Hospital Nacional Dos de Mayo. Lima. Junio – julio. (Quispicondor, 2019).	escoliosis lumbar en el Hospital Dos de Mayo National durante los meses de junio a julio de 2018.		durante los meses de junio a julio de 2018.
Reconocimiento de imágenes para detección temprana de alteraciones posturales (Romero, 2019).	El objetivo de este proyecto es desarrollar un prototipo de sistema de reconocimiento de imágenes para la detección temprana de cambios de posición. Se propone estudiar los argumentos que abarcan temas como: visión artificial y procesamiento de imágenes para lograr los resultados obtenidos, y cabe mencionar que ya se ha mencionado el estudio de las investigaciones realizadas relacionadas con el tema.	<ul style="list-style-type: none"> • Se trata de un documento que nos ilustra sobre el tema de detección de alteraciones por procesamiento de imágenes. 	No se enfoca en un diagnóstico específico a tratar.
Herramienta de apoyo diagnóstico para detección de malformaciones en columna (Guerrero y Guáqueta, 2016).	Tiene como objetivo El objetivo principal Implementar una herramienta de apoyo diagnóstico de malformaciones de la columna, basada en técnicas de visión por computador.	<ul style="list-style-type: none"> • Un análisis de imágenes en tiempo real utilizando Kinect con marcadores en el cuerpo 	<ul style="list-style-type: none"> • Este proyecto utiliza un método innovador sin embargo la precisión del resultado con imágenes en tiempo real presenta un gasto computacional muy elevado para obtener un

Trabajos	Objetivos	Aportes	Brechas
<p>Clasificación de imágenes usando redes neuronales convolucionales en Python (Artola, 2019).</p>	<p>Su principal objetivo es estudiar el funcionamiento interno de las redes neuronales acumulativas y especialmente su utilidad en el análisis de imágenes.</p> <p>Se enfocará en lograr los siguientes puntos: El estudio de las neuronas de inspiración biológica para comprender el mecanismo asociado a ellas y cómo evolucionan para realizar una tarea de aprendizaje.</p>	<ul style="list-style-type: none"> • Un análisis del modelo de neurona artificial y la evolución hasta las redes neuronales convolucionales. 	<p>porcentaje de precisión bajo.</p> <ul style="list-style-type: none"> • El clasificador no tiene una precisión aceptable aun teniendo una base de datos de gran número de imágenes.
<p>“Development and validation of deep learning algorithms for scoliosis screening using back images” (Yang et al., 2019).</p>	<p>Diseñar un aplicativo web para la detección de escoliosis mediante fotografías frontales</p>	<ul style="list-style-type: none"> • Una visión de otros métodos de detección de escoliosis • La precisión de otro clasificador teniendo una muestra de clasificación mayor 	<ul style="list-style-type: none"> • No muestra el esquema del procesamiento de datos a detalle • No delimita ni explica los objetivos muy claramente

Fuente: propia del estudio

CAPÍTULO 3. MARCOS DE REFERENCIA

3.1 MARCO TEÓRICO

En este capítulo del documento se va a concentrar principalmente en la definición de los conceptos del marco teórico y conceptual mostrados a continuación:

Las causas de la Escoliosis idiopática son desconocidas para la ciencia actualmente, aunque se sabe que es el tipo más numeroso, dado que agrupa el 80% de los casos reportados. De acuerdo a la literatura la edad donde hay mayor incidencia se encuentra entre 10 y 14 años y es frecuente en mujeres con un 80%, siendo mayor, dado que se presenta un 20% en varones (Aramendi, 2019; (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016). En ese mismo sentido, se identifica que la escoliosis congénita hace referencia a malformaciones secundarias de la columna vertebral debido a un mal desarrollo de las vértebras en el desarrollo del embrión (Cunin & Raux, 2021).

El término escoliosis viene del griego “*scolios*” que hace referencia a la palabra curvatura (Vargas & Meléndez, 2018). La Escoliosis es una deformidad de tipo morfológica en la columna, que puede presentarse con una curva simple, doble o triple, leve o severa. También puede definirse como la “deformidad del esqueleto axial en tres dimensiones, en donde el plano coronal excede los 10 grados y el desplazamiento lateral del cuerpo vertebral cruza la línea media, regularmente se acompañan de algún grado de rotación” (Vargas y Meléndez, 2018, p. 9).

Hipócrates fue quien hizo la primera descripción de la escoliosis aplicada a todos los tipos de alineación incorrecta de la columna vertebral, en sus estudios descubrió que muchas de estas deformidades ocurrían en personas sanas, pero también reconoció el mal pronóstico

cuando se trataba de una aparición temprana de la enfermedad (Adolescent Idiopathic Scoliosis & Scoliosis Research Society, s. f.; Villavicencio, 2020; Aramendi, 2018).

En la escoliosis se puede presentar varias anomalías:

- Frontal: corresponde a una inclinación lateral de las vértebras.
- Transversal: rotación de las vértebras que origina la gibosidad.
- Sagital: traslación anterior o posterior de la curva que da lugar a una deformidad en las curvaturas fisiológicas (Vargas y Meléndez, 2018; Aramendi, 2018).

La escoliosis puede ser originada por factores como el aspecto genético, el crecimiento y desarrollo, trastornos neuromusculares, metabólicos y hormonales, como también puede deberse a comportamientos adquiridos en el desarrollo de ciertas actividades del ser humano y que involuntariamente la causan como por ejemplo la mala postura al trabajar o estudiar o realizar cualquier actividad, debilidad recurrente en el individuo y desórdenes fisiológicos (Villavicencio, 2020).

3.1.1 Tipos de escoliosis.

3.1.1.1 Escoliosis tipo s.

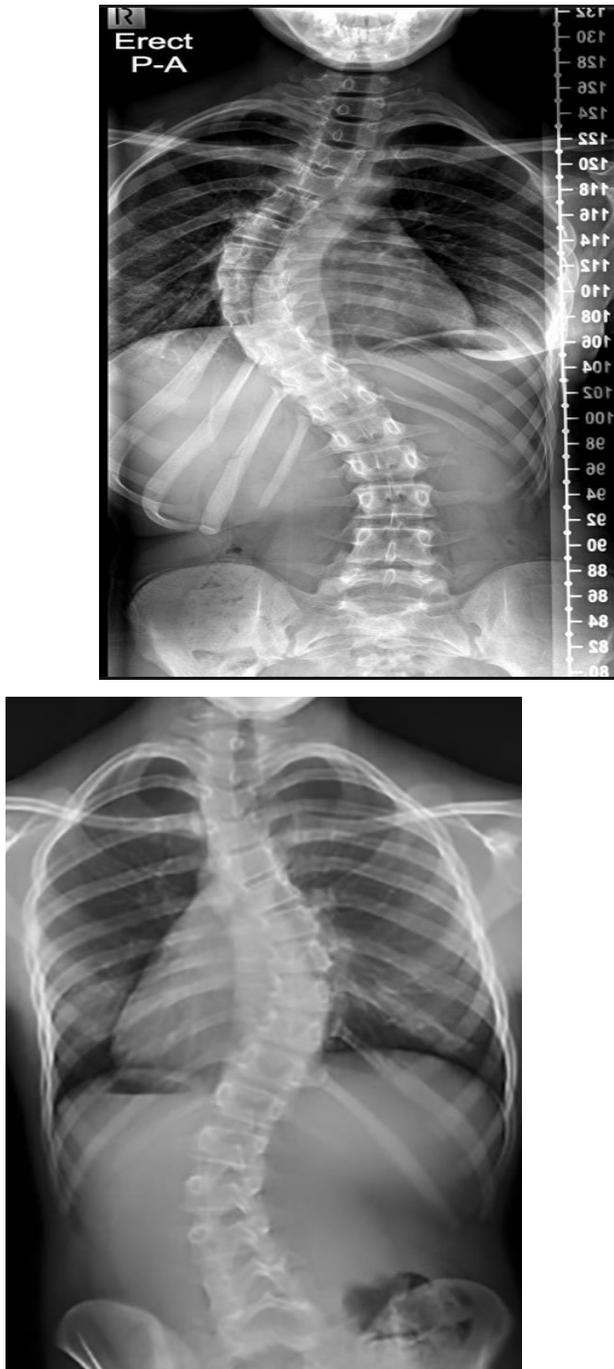
Escoliosis doble con giba y rigidez de la columna, presenta al mismo tiempo el desarrollo de las curvas lumbar y dorsal. Durante la marcha y en la posición erguida en descanso sobre la pierna derecha, se desarrolla una escoliosis doble con rigidez de la columna y con la giba costal en el lado derecho (Figura 3-1).

3.1.1.2 Escoliosis tipo C o escoliosis de una curva.

Este tipo de escoliosis tiene un movimiento de las caderas y consiste en pequeñas limitaciones de los movimientos de la cadera derecha y gran movimiento de la cadera izquierda. Durante la posición erguida, en descanso sobre la pierna derecha, se desarrolla la

desviación fisiológica primaria del segmento lumbar hacia el lado izquierdo y con el tiempo se consolida como una escoliosis de tipo C (Figura 3-1).

Figura 3-1. Escoliosis tipo C y tipo S



Nota: Data set de escoliosis Kaggle 2019 la Figura 3-1 del lado izquierdo de un paciente con escoliosis tipo C y del lado derecho un paciente con escoliosis tipo S

En la Tabla 3–1 se muestran la clasificación según los ángulos de inclinación de la columna.

Tabla 3-1. Escoliosis tipo C.

Cadera izquierda	Cadera derecha
45° / o más	45° / o más
40° / 30°	40° / 30°
15° / 25°	15° / 25°

Nota: cuando la el Angulo que forma del lado izquierdo de la cadera es mayor 30° y del lado izquierdo es mayor a 15° es clasificada como escoliosis tipo C, como se puede notar en la figura 3.0 del lado derecho. Fuente: propia del estudio.

Tabla 3-2. Escoliosis tipo S.

Cadera izquierda	Cadera derecha
45° / o más	45° / o más
40° / 30°	40° / 30°
15° / 25°	15° / 25°
0/10°	0

Nota: cuando la el Angulo que forma del lado izquierdo de la cadera es mayor 30° y del lado derecho es igual a 0 es clasificada como escoliosis tipo S , como se puede notar en la figura 3.0 del lado izquierdo. Fuente: propia del estudio.

3.1.2 Clasificación.

Etimológicamente la escoliosis se clasifica en:

3.1.2.1 Primaria o idiopática.

Representa el 80% de los casos notificados y es más común en mujeres, sin una causa específica. Es más común en adolescentes (Aramendi, 2018; Antón, 2020). Se estima que

esta enfermedad afecta al 2-4% de la población (Cunin & Raux, 2021). De acuerdo a la edad de aparición, existen 3 categorías:

- **Infantil.** Manifestaciones hasta los 3 años de edad. Los varones son los más afectados y esto está estrechamente relacionado con la posición del bebé en decúbito supino. Del 70% al 90%, el problema se resuelve por sí solo (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).
- **Juvenil.** Se manifiesta de 3 a 10 años con niños (Aramendi, 2018).
- **Adolescente.** Desde los 10 años hasta que se completa el esqueleto. El 70% es más común en mujeres (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

En los adultos la evolución de la enfermedad es mucho más lenta, por lo general conduce a la degeneración artrósica con mucho dolor y complicaciones neurológicas, además de agravarse la función respiratoria (Cunin & Raux, 2021).

3.1.2.2 Secundaria o no idiopática.

Se clasifica como:

- **Congénita.** Causada por malformaciones imperceptibles, con desarrollo posterior (mielomeningocele, hemivértebra, fusión congénita de costillas, etc.) (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016)

- **Neuromuscular.** Causada por la falta de activación de los músculos activos estabilizadores de la columna vertebral que ocurren en casos de parálisis cerebral, espina bífida, etc. (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

- **Sindrómica.** Síndromes mesenquimales (síndrome de Marfan, síndrome de Ehlers Danlos), desórdenes metabólicos (osteogénesis imperfecta), neurofibromatosis y osteocondrodistrofias (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

- **Otras causas.** Enfermedad reumatoidea, traumática (fractura, cirugía) o tumores óseos de la columna vertebral (osteoma osteoide) y medulares (Aramendi, 2018; Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016).

3.1.3 Pruebas diagnósticas.

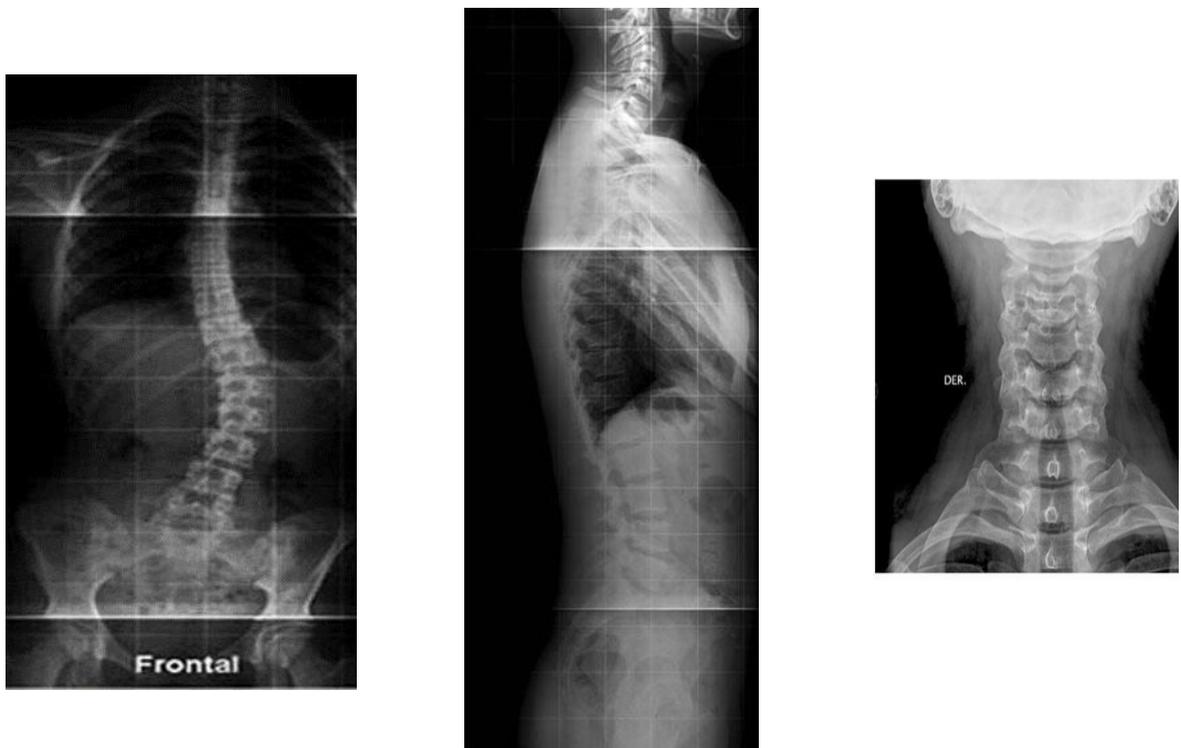
Entre éstas están las radiografías, tomografía axial computada, resonancia magnética y electromiografía.

3.1.3.1 Radiografías.

Es una herramienta que permite ver el grado de curvatura patológica de la columna en plano sagital y coronal, además permite otras mediciones con diferentes métodos y verificar el estado de la deformidad y con base a resultados tomar decisiones (Villavicencio, 2020; Pascal, 2020).

Primeramente, se solicitan radiografías frontal, lateral y axial (Figura 3–2).

Figura 3-2. Radiografías frontal, lateral y axial.



Fuente: Villavicencio, (2020).

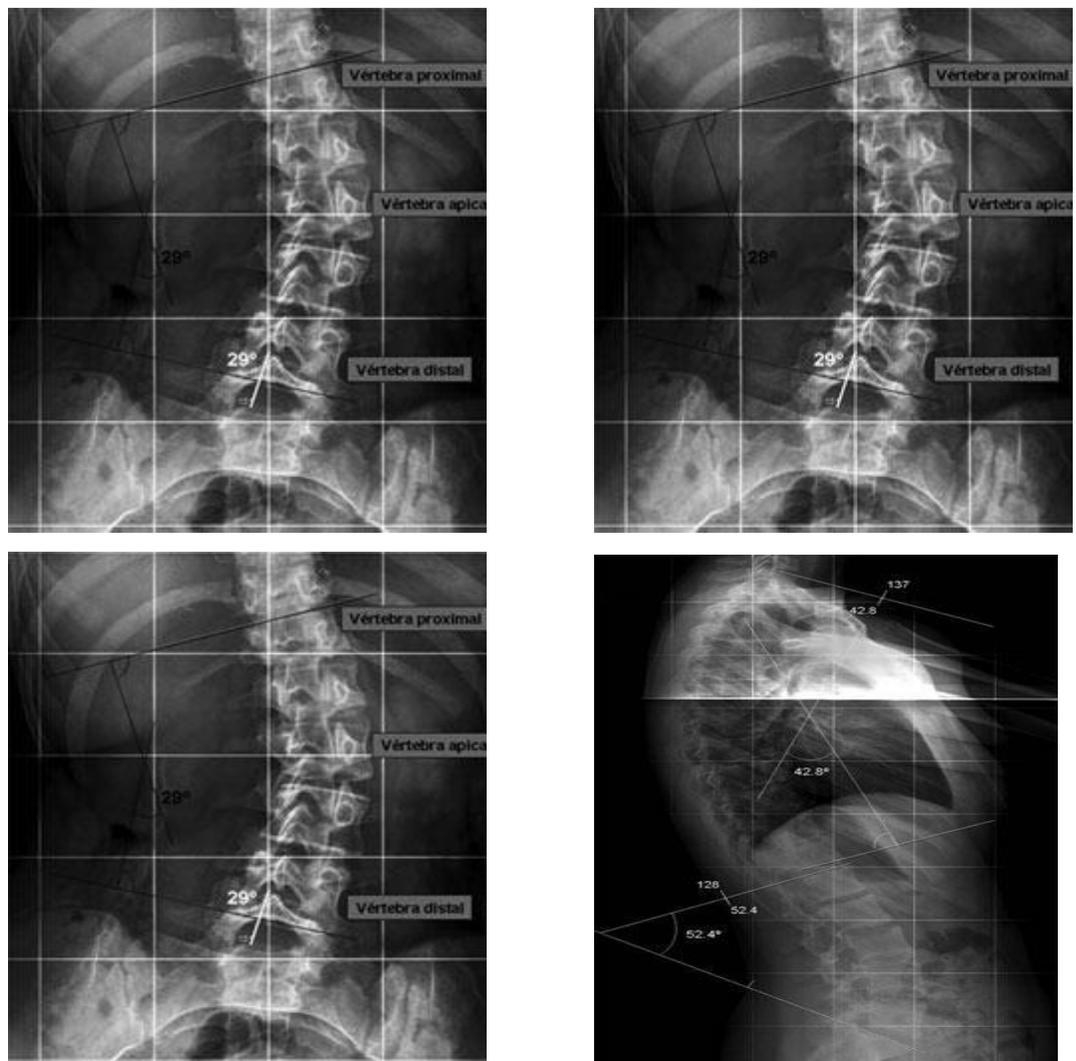
Existen diferentes métodos o técnicas para realizar las mediciones radiográficas:

- **El método de Cobb.** Es muy utilizado para medir la curvatura patológica o fisiológica de la columna en los niveles sagital, posterior y lateral. El objetivo de este método es medir el ángulo que se forma a causa de la intersección de dos líneas paralelas al plano superior

de la vértebra proximal y al plano menor de la curvatura lateral distal (Villavicencio, 2020; Quispicondor, 2019); Quispilaya y Recuay, 2019; Zardo et al., 2017), este método se observa en la Figura 3-3.

Según el método Cobb, la escoliosis puede ser leve (menos de 20° Cobb), moderada (entre 20° y 45° Cobb) y severa: más de 45° Cobb (Villavicencio, 2020; Quispicondor, 2019); Quispilaya y Recuay, 2019).

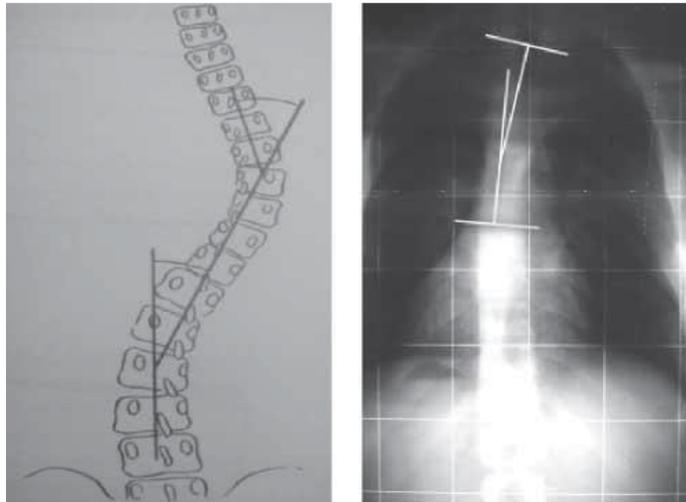
Figura 3-3. Método de Cobb



Fuente: Quispicondor, 2019).

- **Método de Ferguson.** Se utiliza para medir la curvatura y se realiza cuando las partes periféricas del cuerpo vertebral no se pueden ver con facilidad, una de las cuales es la escoliosis congénita (Quispicondor, 2019; Quispilaya y Recuay, 2019).

Figura 3-4. Método de Ferguson.



Fuente: Quispicondor, 2019

Como se observa en la Figura 3–4, el especialista ubica un punto en el medio de la sombra del cuerpo en las tres vértebras (dos terminales y dos apicales). La apical es la más rotada en la cresta de la curva; traza líneas desde la parte más alta o vértice de cada extremo, de manera que el ángulo de la curva es el espaciado de las líneas alrededor de 180 grados (Quispicondor, 2019; Quispilaya y Recuay, 2019).

b) Resonancia magnética. Se realiza cuando se sospecha de patologías del canal raquídeo, especialmente se considera en la escoliosis congénita que viene asociada con este tipo de patologías como la malformación de Arrol–Chiari, siringomielia, diastomatomielia

y médula anclada (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016; Quispicondor, 2019; Quispilaya y Recuay, 2019).

c) Tomografía computada. Este procedimiento permite delinear mejor los detalles de las anomalías vertebrales, sobre todo cuando es necesaria la intervención quirúrgica, es restringida por la dosis de radiación ionizante que el paciente recibe (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016; Quispicondor, 2019; Quispilaya y Recuay, 2019).

d) Electromiografía. Permite medir el grado de afectación neurológica (Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vertebral, 2016; Quispicondor, 2019; Quispilaya y Recuay, 2019).

3.1.4 Redes neuronales artificiales.

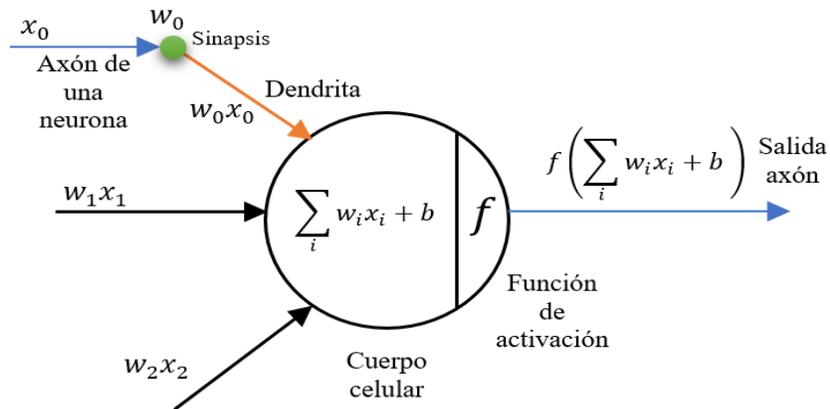
Por otro lado, se aborda el concepto de red neuronal artificial, que se entiende como un modelo que imita la manera en que el cerebro humano procesa la información y posteriormente la clasifica (Artola, 2019). Este sistema se instaura desde la interconexión de diversos elementos inteligentes e independientes denominados neuronas. De modo que dichos sistemas se estructuran jerárquicamente, cada capa tiene un número diferente de neuronas. Estas interconexiones se miden mediante ciertos pesos, que el filtro aplica a la salida de la neurona anterior. A continuación, el sumador se coloca al total de las entradas de cada neurona en la capa posterior, con el fin de acabar el cálculo de una función no lineal de activación para cada suma (Jiménez de las Heras, 2018).

En el siguiente capítulo se incluyen términos referentes para enfocar, diseñar, estructurar y desarrollar el clasificador basado en redes neuronales para la detección de escoliosis en imagen Rx de columna, partiendo de la anatomía de la columna, su fisiología,

patología, pasando a la técnica imagen de Rx, la descripción de las redes neuronales y explicando principios básicos para conseguir la formación de la imagen a partir de las redes convolucionales.

A menudo llamada nodo o unidad, una red neuronal es responsable de recibir datos de otros nodos o provenientes desde una fuente externa y de calcular un valor de salida estimado. Cada variable de entrada tiene un peso asociado (w) asignado de acuerdo a su importancia relativa para las demás entradas. La suma de las entradas multiplicadas por sus pesos asociados establece el "impulso neural" recibido por la neurona, es decir, una función de la suma de las entradas pesadas: es la suma de todos los valores de entrada de la neurona, multiplicado cada uno de los pesos. Luego, se aplica una función de activación en la suma ponderada de sus entradas (Jiménez de las Heras, 2018; (Flores, 2017) (Figura 3–5).

Figura 3-5. Red neuronal artificial.



Fuente: Jiménez de las Heras, 2018.

$$\sum_i w_i x_i + b \quad (1)$$

w_i : pesos sinápticos.

x_i : datos de entrada.

b : valor de umbral.

En la Figura 3–5, se observa un modelo de neuronal artificial que se asemeja a una biológica, en la anterior ecuación que es la fórmula matemática que se asemeja al cuerpo

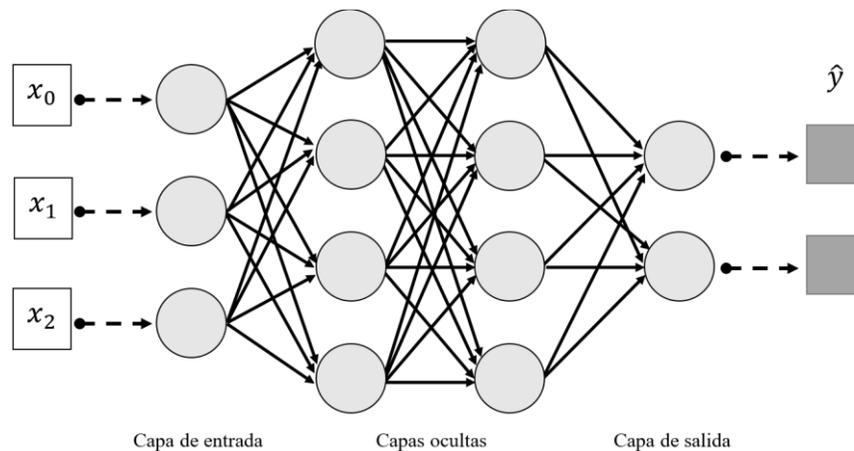
celular de una neurona los parámetros de entrada son las x_i , los pesos son los w_i y los umbrales b utilizados para realizar la sumatoria representada en la ecuación (3.1), y después pasa por una función de activación para obtener las salidas \check{Y} , donde j es un elemento de r neuronas.

Específicamente, varias unidades operan paralelamente y no existe una unidad de control central. Así, la red neuronal se compone de una serie de neuronas a modo de peso, que son una vía de almacenamiento de información permanente y actualizado (Jiménez de las Heras, 2018; Flores, 2017), Tras el final de la red, se obtendrá una salida (salida axón), que será la predicción calculada por la red. De esta manera, las neuronas biológicas y artificiales tienen similitudes, ya que tienen entradas, usan pesos y producen salidas

- a) **Red monocapa:** Las neuronas se interconectan con otras y son de una única capa. Son utilizadas en la autoasociación (información distorsionada o incompleta que es regenerada de entrada) (Jiménez de las Heras, 2018; Serna et al., 2017).

- b) **Red multicapa:** multicapa. Son redes formadas por neuronas ubicadas en diferentes capas. Estas conexiones se denominan feedforward o reenvío porque reciben información de la capa anterior y envían la información a la capa superior. Como puede verse en la Figura 3–6, la red se constituye por la capa de entrada, capa oculta y capa de salida; Los datos pasan a través de la "capa de entrada", luego a la "capa oculta" y, por último, llegan a la "capa de salida".

Figura 3-6. Red de neuronas artificiales.



Fuente: Jiménez de las Heras, 2018.

Por tanto, cada nodo se interpreta como un clasificador lineal, donde se utiliza la función definida por el peso “ W ”.

$$s=Wx+b \quad (2)$$

Donde:

Wx = pesos

b = bias o sesgos

El parámetro bias, “ b ”, en caso de no estar balanceado el conjunto de datos, o en otras palabras, la función del bias intenta nivelarlo (Jiménez de las Heras, 2018; Serna et al., 2017). Existen dos etapas para el uso de redes neuronales: aprendizaje y generalización; donde los datos de entrenamiento o el modelo usado para calcular los pesos de la red, comenzando con un cierto valor aleatorio, se cambian iterativamente usando los datos de prueba, por lo que los costos de la función seleccionada se minimizan

3.1.5 Redes neuronales convolucionales.

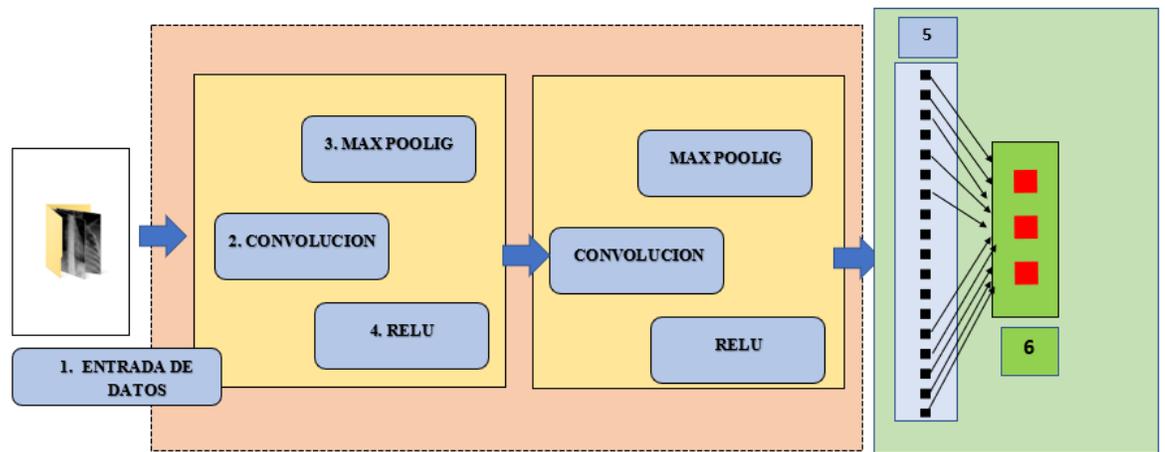
Las redes convolucionales son una generalización de las redes neuronales clásicas. Su nombre proviene del hecho de que, al aumentar este tamaño, los pesos ya no serán numéricos, sino más bien una matriz n-dimensional, llamada filtro, que se aplica a la convolución de la entrada para obtener su salida.

Las redes neuronales convolucionales (RNC) se utilizan de forma eficiente para el análisis de imágenes, también para reconocimiento y clasificación de imágenes. Además, tiene cuatro operadores principales, los cuales son la entrada, convolución, pooling, ReLU.

3.1.6 Partes de una red neuronal convolucional (RNC).

En general, una RNC es una red neuronal artificial jerárquica que consta de los siguientes elementos: entrada, convolución, agregación, ReLU, capa totalmente conectada y, finalmente, la capa superior. Las capas de deformación y contracción se pueden repetir muchas veces según el modelo y permiten capturar las características más típicas de la imagen. La clase está totalmente conectada, puede ser única o múltiple, lo que unifica los resultados para realizar la clasificación. Al final de la capa de salida aparece la probabilidad de que la imagen de entrada sea: escoliosis tipo C o tipo S.

Figura 3-7. Estructura de la RNC



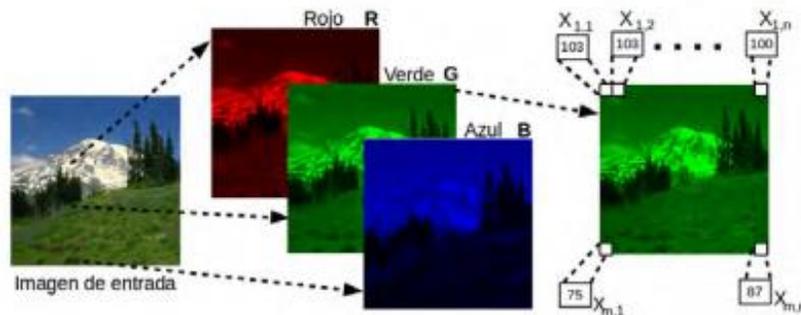
Nota: En la figura se aprecia como está distribuida la red neuronal convolucional, del algoritmo de clasificación del presente trabajo.

3.1.7 Extracción de características.

Imagen de entrada. Las imágenes de entrada son presentadas como una matriz de $W * L$ (W =ancho, L = largo), donde cada valor de la matriz representa un valor de pixel de la

imagen. Si se trabaja con una imagen a color o RGB se tienen 3 matrices de $W * L$ como se muestra en la Figura 3.8.

Figura 3-8. Matriz RGB.



Nota: Se muestra las diferentes matrices de la imagen como es la matriz para el color azul, rojo, verde y los valores de la matriz que representan el valor de los pixeles. (López, 2019, p. 24)

Para la imagen de entrada del clasificador se trabaja con imágenes de $W * L$ pero solo se utilizaron imágenes en escala de grises con un tamaño, como cada imagen tiene un tamaño diferente éstas se normalizan de tamaño $M * M$. Para nuestro caso, se estandarizó de tamaño $W * L = 224 * 224$. En la siguiente figura se muestra un lote 4 de imágenes estandarizadas del clasificador.

Figura 3-9. Lote de imágenes de entrada.



Nota: lote imágenes de entrada estandarizadas. Fuente propia.

3.1.8 Convolución.

Con los datos de la imagen normalizada se puede realizar la operación de convolución. La convolución es la unidad básica de la RNC y por la cual recibe su nombre, y es la operación que realiza la mayor parte del procesamiento de la imagen a tratar. El uso de las redes neuronales convolucionales se utiliza generalmente para mejorar la calidad de la imagen, la nitidez, detectar bordes, entre otros aspectos (López, 2019, p. 24).

La convolución opera principalmente dos matrices, una es la matriz de entrada ya normalizada, la otra es una matriz llamada kernel (K), esta matriz puede ser de 3*3, 5*5, en general de $k \times k$, en nuestro caso utilizaremos un kernel de 3*3. La operación de convolución entre dos funciones $A(x, y)$, y $K(x, y)$ de tamaño $W * L$ denotada por $A(x, y) * K(x, y)$ está definida por la ecuación 2.2 en discreto-bidimensional.

$$C[x, y] = A[x, y] * K[x, y] = \frac{1}{WL} \sum_{w=1}^{W-1} \sum_{l=1}^{L-1} A[w, l]K[x - w, l - y] \quad (3)$$

$x = 1,2,3,4,5 \dots \dots$, Ancho de la imagen, $y = 1,2,3,4,5 \dots \dots$, Alto de la imagen

Donde:

*: indica la operación de convolución discreta bidimensional,

A: es una matriz de la imagen de entrada,

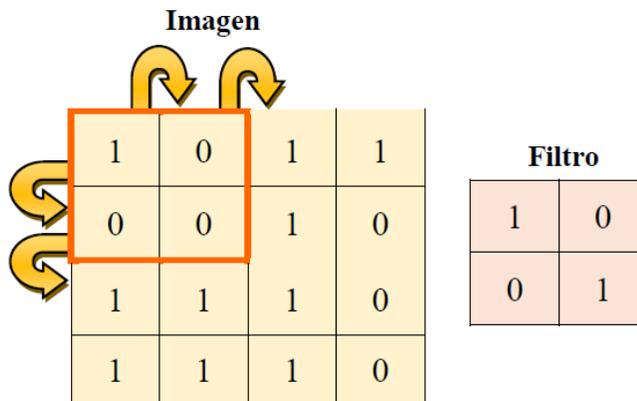
K: es el kernel utilizado

$\frac{1}{WL}$: se normaliza al tamaño de la imagen,

En nuestro caso se trabaja con matrices cuadradas de $k \times k$ con $W= k$, $L= k$.

A continuación, en la Figura 3-9, se ejemplifica una convolución, que consiste en la matriz de 4x4 con un filtro de 2x2.

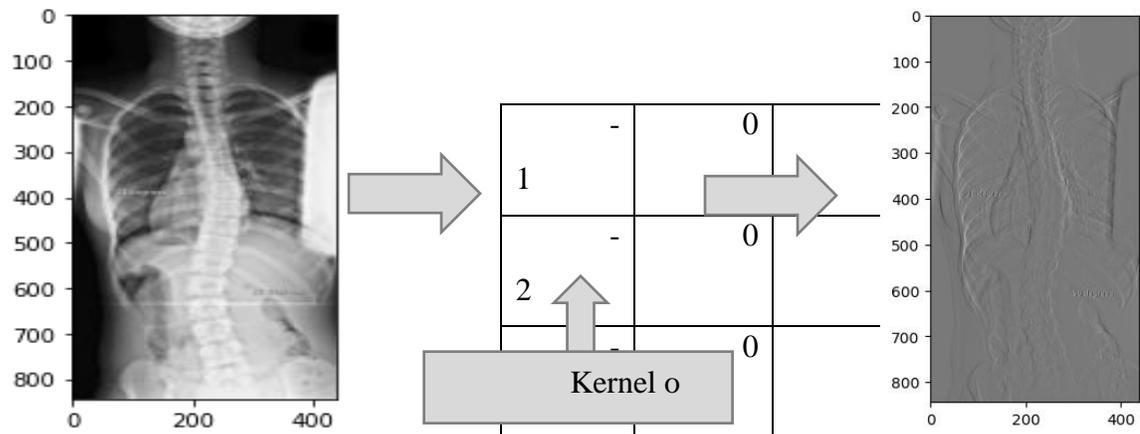
Figura 3-10 Convolución sobre la matriz de una imagen.



Fuente: Jiménez de las Heras, 2018)

De hecho, la red neuronal convolucional aprende los valores del filtro por sí misma durante la fase de aprendizaje. Libremente de cuál sea el valor, durante el entrenamiento, deberá continuar especificando varios parámetros como: número de filtros, tamaño de filtro, entre otros. El uso de filtros diferentes posibilita seleccionar varios rasgos y características de una imagen, como bordes y curvas (Chanampe et al., 2019; Hernández et al., 2019).

Figura 3-11. Convolución sobre la matriz de una imagen.



Nota: imagen de entrada del lado derecho y del lado izquierdo la imagen cuando se le aplica la convolución con un kernel de $k \times k$.

3.1.9 Pooling.

El objetivo del Pooling principalmente reducir la salida de la capa de convolución, de modo que la cantidad de características también sean reducidas, manteniendo la información más representativa de la imagen. Así se reduce la resolución de los atributos y los hace robustos al ruido y distorsión. El parámetro usado es una máscara M de tamaño $k \times k$ y paso ρ . Existen diferentes tipos de pooling, pero los más utilizados son:

- **Average-pooling:** obtiene el valor promedio de los elementos j de una región R_i de una imagen $I(x, y)$ de tamaño $N \times N$. La podemos definir como:

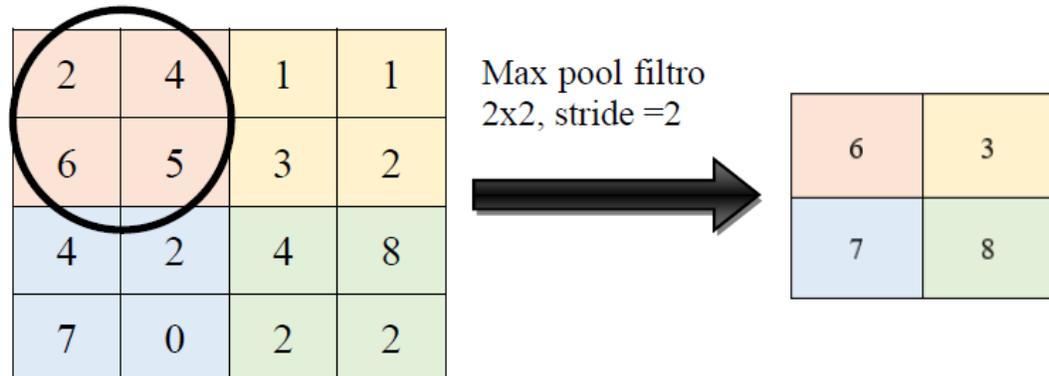
$$AP = \frac{1}{k * k} \sum_{i \in [k * k]} R_i \quad (4)$$

- **Max-pooling:** obtiene el valor máximo de una región R_i de tamaño $k \times k$ de $I(x, y)$ de tamaño $N \times N$. La podemos definir como:

$$MP = \text{máx}\{R_i\} i \in [k * k] \quad (5)$$

Un ejemplo práctico para max-pooling es el que se muestra en la figura 3.12, en donde se divide la matriz R en cuatro regiones con máscara de 2×2 , y en cada región se obtiene el máximo, en la primera región podemos tomar a $[2, 4, 6, 5]$, de estos cuatro números la media es 4 (AP) utilizando average-pooling, o en la matriz 2 (MP) utiliza max-pooling donde el máximo es 6 en la Figura 3–11 se observa el max pooling:

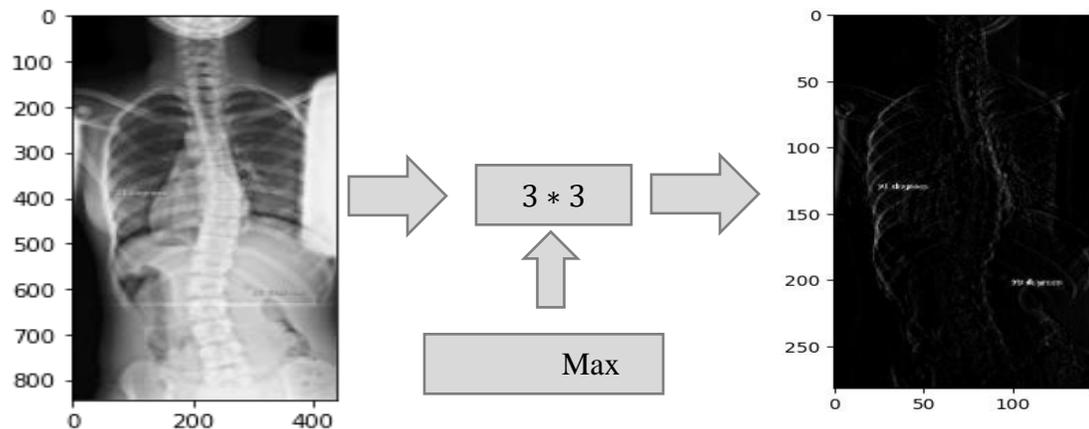
Figura 3-12. Max Pooling.



Nota: Fuente Jiménez de las Heras, 2018

Se selecciona una ventana de 2x2 y se seleccionará la mayor cantidad de mapas de características en la ventana. Esta ventana, se desplaza con un paso de “2” (stride con valor igual a “2”) y selecciona el máximo de cada región (Rodríguez, 2017).

Figura 3-13.1 Max Pooling aplicada.



Nota: se muestra la función de Pooling

3.1.10 Activación no-lineal de la red.

Para que la RNC funcione se necesita de la función de activación que, dada una o varias entradas, define la salida de una neurona en una red. Existen distintas funciones, siendo

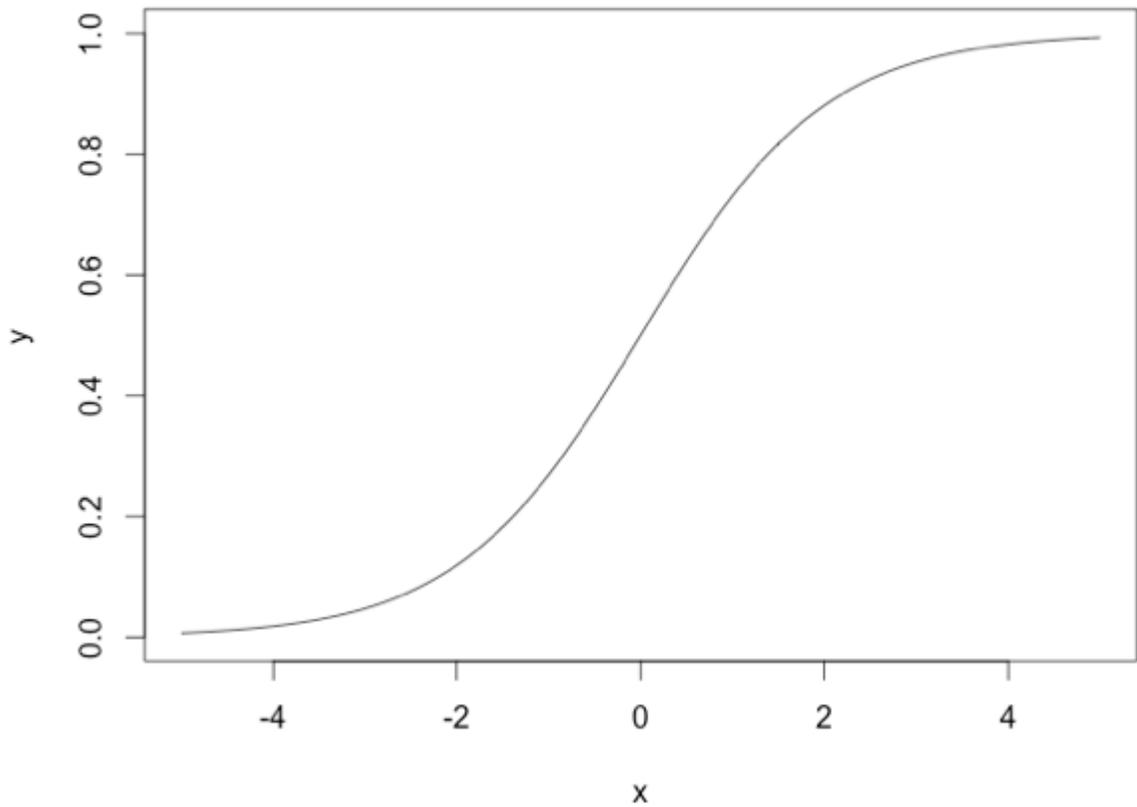
las más importantes la sigmoide, la tangente hiperbólica y la ReLU, las cuales se explican a continuación:

3.1.10.1 Sigmoide.

Dado por la ecuación 2.5, ver figura 3.1(A).

$$Y(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

Figura 3-14. Función de activación sigmoide.



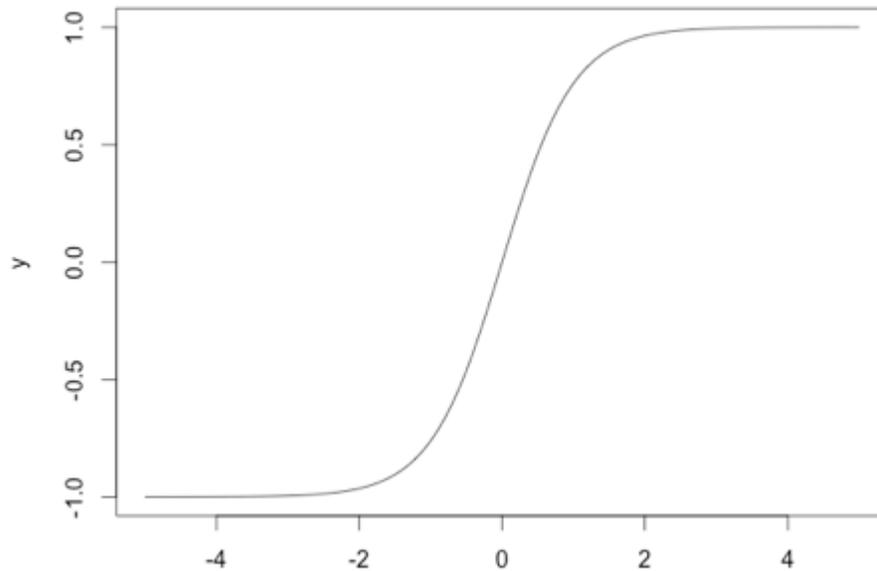
Nota: se muestra la función de activación sigmoide. Bisong (2019).

3.1.10.2 Tangente hiperbólica.

Dado por la ecuación 2.6 y su gráfica se muestra en la Figura 3.12.

$$\varphi(x) = \tanh(x) \quad (7)$$

Figura 3-15. Función de activación tangente hiperbólica.



Nota: se muestra la función de activación tangencial hiperbólica. Bisong, E. (2019).

3.1.10.3 ReLu.

La función de activación ReLU (rectificador lineal) como sus siglas en inglés lo denotan permite tener un gradiente pequeño cuando no está activada la neurona en nuestra red convolucional, esta función ayuda a las redes neuronales a formar modelos de aprendizaje profundo. Debido a los problemas de gradiente de fuga en diferentes capas, no se puede utilizar la tangente hiperbólica y la activación sigmoide.

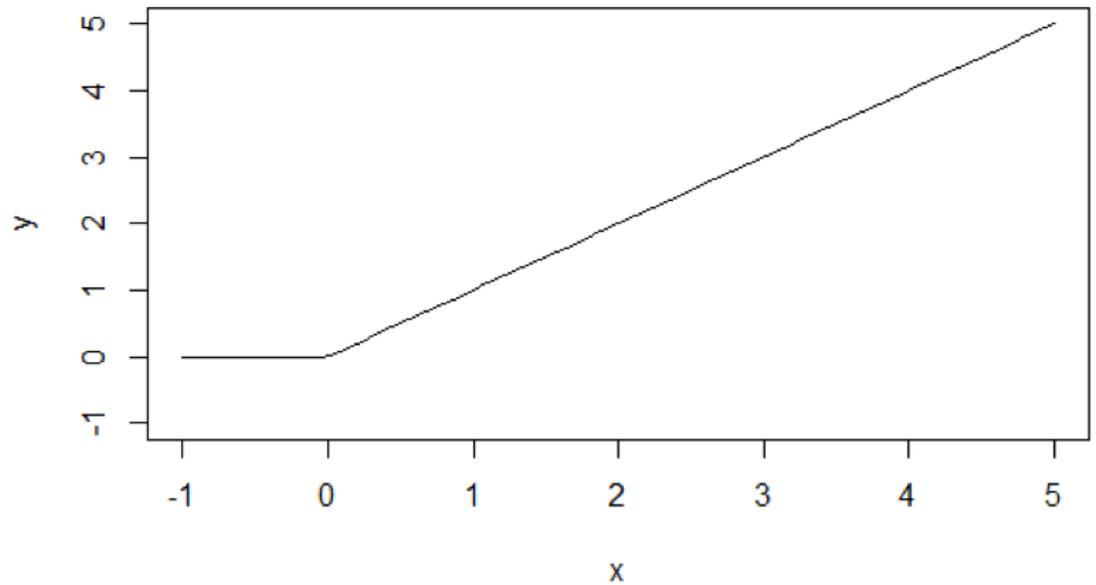
Puede superar los problemas de gradiente mediante la función de activación Relu. Esto permite que el modelo funcione mejor y aprenda más rápido. Cuando desarrolle el Perceptrón convolucional y multicapa, la función de activación lineal rectificadora de las redes neuronales será la opción por defecto la función de activación se puede calcular mediante la ecuación 28, en la figura 3.28 se muestra la función de activación ReLu. (Rodríguez, 2017, Hernández et al., 2017).

$$R(x) = \text{máx}(0, x) \quad (8)$$

Donde $x \in X$

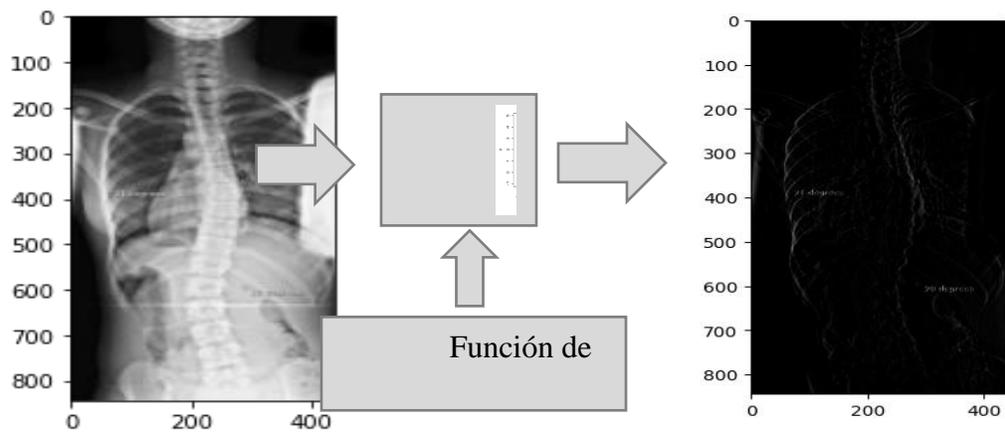
Donde: X = la matriz de entrada

Figura 3-16. **Función de activación.**



Nota: se muestra la función de activación ReLu hiperbólica. Bisong, E. (2019).

Figura 3-17. **Función de activación ReLu aplicada.**

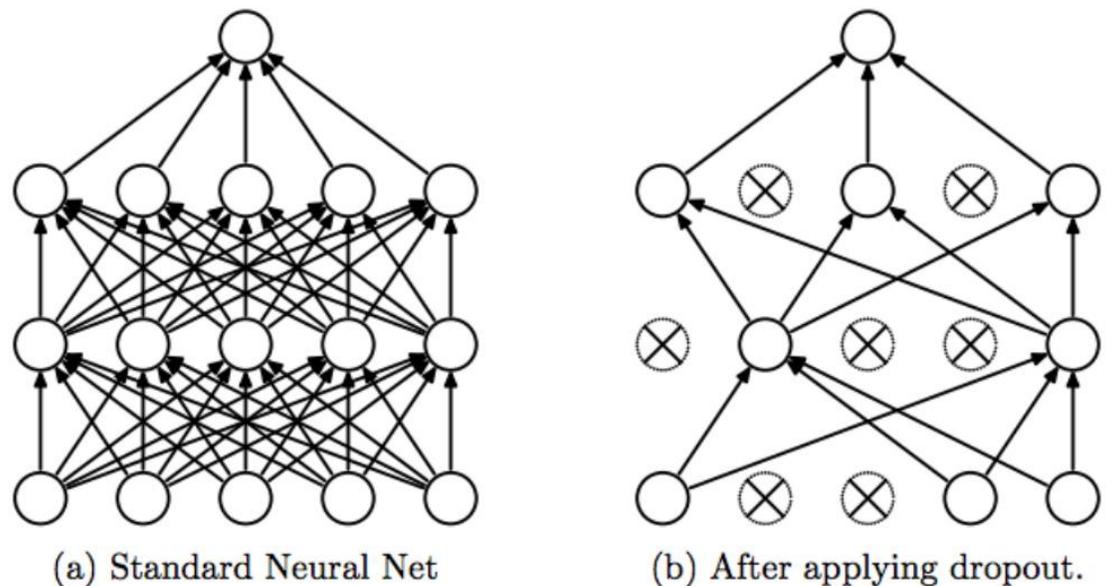


Nota: se muestra la función de activación ReLu.

3.1.11 Dropout.

Esta función nos permite desconectar un cierto porcentaje de neuronas de forma aleatoria en cada intervalo de entrenamiento como lo muestra la Figura 3.18, así los nodos habilitados ayudan a que la red sea más específica. Es utilizada principalmente para reducir el sobre-entrenamiento.

Figura 3-18. Dropout.



Nota: en la figura de la derecha se puede ver una red neuronal estándar y la figura del lado izquierdo se puede observar cuando se le ha aplicado la función de Dropout que en nuestro caso se desactivó un 0.5 (Bisong, 2019).

3.1.12 Softmax.

La función de salida softmax corresponde a una generalización de la función sigmoidea y se populariza mediante redes neuronales integradas. Se utiliza como la función de activación de salida para el clasificador multiplicarse porque escala las entradas anteriores de un rango de 0 a 1 y normaliza la clase de salida a la suma de todas las neuronas. La salida es igual a la unidad.

Esta función se considera una distribución de probabilidad categórica, esto le confiere transmitir cierto grado de confianza en las predicciones.

$$S_j(x) = \frac{e^{x_j}}{\sum_{k=1}^n e^{x_k}} \quad \forall_j = 1, 2, 3, 4 \dots \dots n \quad (9)$$

Donde:

x_j = es el valor de un elemento de la última capa totalmente conectada.

n : es el número de elementos de la capa de salida.

Todos los valores de salida están entre 0 y 1 y la suma es igual a uno.

3.1.13 Capa de salida.

El trabajo principal de esta capa es mostrar el resultado del análisis hecho por las capas anteriores, donde muestra, que la probabilidad de éxito de que la imagen de entrada sea escoliosis tipo S o C el resultado se muestra en un porcentaje para nuestro caso fue de 94%. Es importante recalcar que pueden ser varios los resultados de salida con diferentes probabilidades de éxito, esto depende de la arquitectura de la RNC.

3.1.14 Métodos de aprendizaje.

3.1.14.1 ADAM

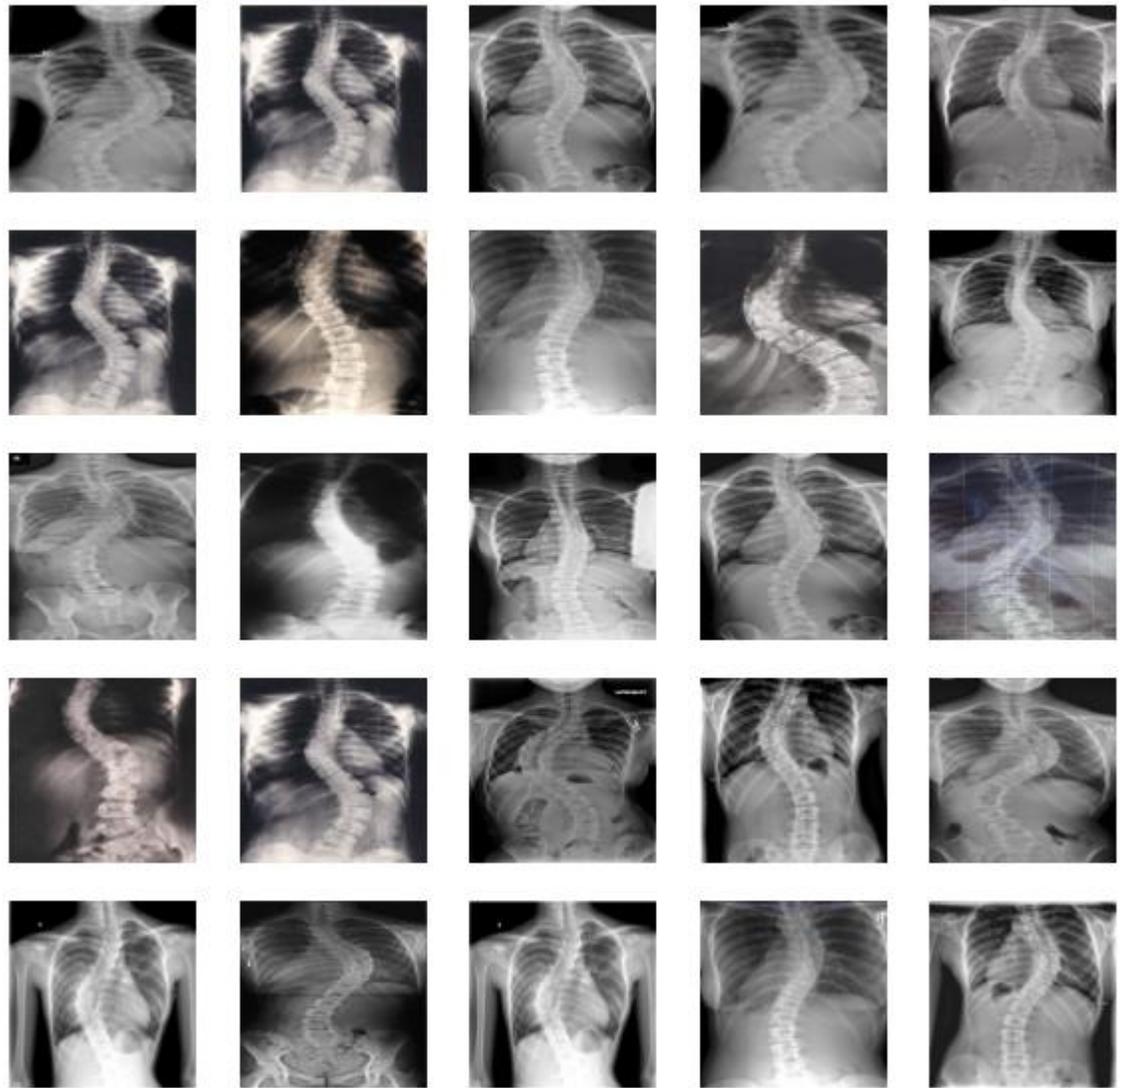
(Adaptive Moment Estimation). El algoritmo de optimización utilizado en este trabajo es "Adam", que es una actualización del optimizador RMSprop (método de aprendizaje). Se diferencia de otros algoritmos de optimización en que mantiene la misma tasa de aprendizaje para todos los pesos actualizados y esto no se transforma durante el entrenamiento de RNC. En este caso particular, interfiere con la red neuronal de la siguiente manera, puede actualizar iterativamente los pesos de la red de acuerdo con los datos de entrenamiento (Jiménez de las Heras, 2018; Serna et al., 2017).

3.1.15 Evaluación.

La evaluación del rendimiento de las redes neuronales convolucionales puede centrarse en la optimización (precisión) del entrenamiento y la generalización de las pruebas. La optimización se refiere al proceso de adaptar la red para lograr el mejor rendimiento posible con los datos de entrenamiento. La generalización se refiere al buen funcionamiento de la red entrenada. con datos que nunca ha visto, como datos de prueba, influenciados por conjuntos de imágenes, algoritmos de aprendizaje, software, recursos informáticos utilizados, entre otras variables.

Primero, se separa un conjunto “set” de imágenes para entrenamiento “training_set” como se muestra en la figura.3-19 en el presente clasificador y otro para prueba “test_set”, la RNC se entrena y finalmente se evalúa con las imágenes no aprendidas. Se describe primero el entrenamiento, luego la validación y finalmente la prueba.

Figura 3-19. Conjunto imágenes de entrenamiento.



Nota: se muestra el conjunto de imágenes de entrenamiento “training_set”.

3.1.16 Entrenamiento.

El método utilizado para llevar a cabo el proceso de aprendizaje en una RNC se representa como entrenamiento. Como vimos anteriormente en el algoritmo de aprendizaje ADAM que pueden resultar interesantes ya que presentan distintas características y

rendimiento que los pueden hacer más o menos adecuados dependiendo de las características del problema concreto a resolver.

Un buen desempeño en el entrenamiento no significa que se logre una buena precisión en la prueba. El problema a considerar es el sobreajuste o overfitting, ya que el valor del parámetro se adapta demasiado bien a la experiencia del ejemplo de entrenamiento sesgado y es óptimo en cuanto minimiza el error de generalización dado por la función de pérdida (Amari et al., 1997).

Para entender el entrenamiento en una RNC es necesario conocer ciertos parámetros, como son:

- **Lote:** Al entrenar la red, debe ingresar las imágenes en la red. Puede ingresar una o más imágenes. La desventaja de hacer esto individualmente es que no se utilizan todos los recursos disponibles, lo que resulta en tiempos de procesamiento de datos más largos. Otra forma es ingresar varias imágenes y procesarlas en paralelo según el recurso.

Durante el entrenamiento de RNC, ciertas imágenes o "lotes" [8] se extraen aleatoriamente de la base de datos de entrenamiento. Por ejemplo, en la primera iteración, una serie de imágenes [1,2,3,4,5N] se pueden extraer de la base de datos para el primer análisis, estas imágenes pasan por la red modificando los pesos y compensaciones, en la iteración siguiente, se extraen aleatoriamente otras imágenes [1,2,3,4,5N], hasta completar el mayor número de iteraciones. La cantidad de lotes depende de la CPU o GPU RAM que tenga, si la cantidad de información excede la memoria, no podrá entrenar la red.

En la RNC implementada en el presente trabajo lote de 5 a 15 imagen por los bajos recursos computacionales.

- **Época:** una época se completa cuando todo el entrenamiento pasa por la red de aprendizaje, por ejemplo, si hay 20 000 imágenes para el entrenamiento y el lote es 32, una época se completa cuando hay 625 iteraciones porque cada lote es una iteración. obtenido con la siguiente ecuación:

$$\frac{NI}{Lote} = \frac{20000}{32} = 625 \text{ iteraciones} \quad (10)$$

Donde: *NI* (número de imágenes), *Lote*

Para el entrenamiento se utilizó la una base de datos de Kaggle a continuación se da a conocer que es y generalmente para que se utiliza.

3.1.17 Kaggle.

Kaggle es una plataforma que posee a disposición de los usuarios una serie de problemas para solucionar con temáticas como la ciencia de datos, el análisis predictivo y lo machine learning para nuestro análisis hemos encontrado una base de datos echa por un usuario de la plataforma llamada Tipos de escoliosis como se muestra en la Figura 299. (Types of Scoliosis, n.d.). Cuenta con un set de datos de entrenamiento y de prueba de imágenes de escoliosis con un total 78 imágenes que se distribuyen (39 equipos de prueba), (39 conjunto de entrenamiento) de las cuales para nuestro algoritmo de clasificación solo se utilizó las 39 imágenes del conjunto de entrenamiento.

Figura 3-20. Base de datos de Kaggle.



Nota: base de datos de escoliosis utilizada en el algoritmo de clasificación.

3.1.18 Validación.

El conjunto de datos de validación se usa para ajustar los pesos en la nueva imagen después del entrenamiento. Después de la validación, puede usar el conjunto de datos de prueba para evaluar el rendimiento. Durante el entrenamiento y la validación, es importante decir que la red continúa aprendiendo y necesita imágenes clasificadas.

3.1.19 Google Colaboratory.

Para la puesta en marcha del algoritmo de clasificación se utilizó Google Colaboratory, Google Colaboratory (también conocido como Colab) es un plan cuyo objetivo es extender la educación y la investigación sobre el aprendizaje automático. Los cuadernos colaboratorios se basan en Jupyter y funcionan como un objeto de Google Docs: se pueden compartir y los usuarios pueden colaborar en el mismo cuaderno. Colaboratory proporciona tiempos de ejecución de Python 2 y 3 preconfigurados con las bibliotecas esenciales de aprendizaje automático e inteligencia artificial, como TensorFlow, Matplotlib y Keras. La máquina virtual (VM bajo el tiempo de ejecución) se desactiva después de un período de tiempo y se pierden todos los datos y configuraciones del usuario. Sin embargo, el portátil se conserva y también es posible transferir archivos desde el disco duro de la VM a la cuenta de Google Drive del usuario. Finalmente, este servicio de Google proporciona un tiempo de

ejecución acelerado por GPU, también completamente configurado con el software descrito anteriormente (Google, 2018).

CAPÍTULO 4. MATERIALES Y MÉTODOS

4.1 MATERIALES

El empleo y aplicación del clasificador basado en redes neuronales para la detección de escoliosis en imagen RX de columna se realizó en un computador con Procesador Intel Pentium CPU G645T @2.50 Hz, 4 Gb de Ram, con un sistema operativo Windows 64 bits, procesador x64.

4.2 METODOLOGÍA.

La metodología que siguió fue:

- Extraer, el conjunto de imágenes (Types of Scoliosis) que serán utilizados.
- Después, separa las imágenes en entrenamiento y prueba.
- Posteriormente, se realiza el diseño y la construcción de la red
- Finalmente se entrenamos y valida la red diseñada. En la figura 4.1 se muestra la metodología seguida para el desarrollo del algoritmo.

Figura 4-1. Estructura de la metodología.



Nota: Estructura de la metodología.

Para desarrollar el presente trabajo, se extraen los datos de la base de datos de Kaggle, de la cual se descarga el conjunto de datos “Starter: Types of Scoliosis 50904dd4-0”, esta base de datos contiene 39 casos de escoliosis, los primeros 19 casos son de pacientes con escoliosis tipo c, los 20 restantes son de escoliosis tipo s como se muestra en la figura 32c, para la validación se utilizó un banco de imágenes que fue entregado por el radiólogo del

Hospital Sagrado Corazón de Jesús (HSCJ) que cuenta con un total de 24 imágenes de pacientes con escoliosis 10 casos son de pacientes con escoliosis tipo C, los 14 restantes son de escoliosis tipo S.

Tabla 4-1. Conjunto de datos.

Conjunto de datos	Clases	Tamaño			Total
		Altura	Ancho	Profundo	
Types of Scoliosis		500	534	3	25
banco de imágenes HSCJ		123	145	3	25
Pacientes sanos	4	600	700	3	25

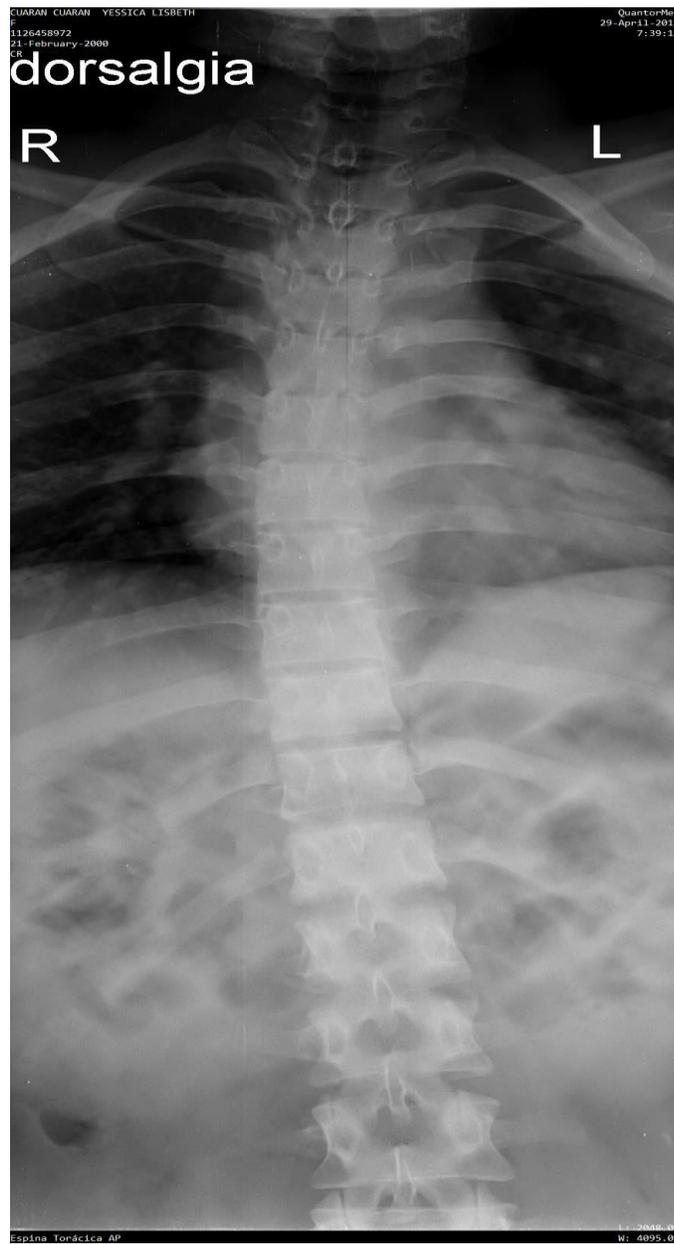
Nota: distribución de las imágenes.

Figura 4-2. Imagen Types of Scoliosis.



Nota: imagen de entrenamiento de paciente con escoliosis tipo S.

Figura 4-3. Imagen Hospital Sagrado Corazón de Jesús.



Nota: imagen de validación de paciente con escoliosis tipo c.

Figura 4-4. Imagen de paciente sano.



Nota: en la figura se muestra una radiografía de un paciente que no presenta escoliosis.

En total, la base de datos contiene 75 imágenes. Hay 25 personas con escoliosis tipo C y 25 con escoliosis tipo S, pacientes sanos. Por lo tanto, nuestra red neuronal se clasificará en las siguientes dos categorías: " Escoliosis tipo C ", " Escoliosis tipo S" y "pacientes sanos". (Kerneler, 2019).

También es importante exponer que para cargar la base de datos se tiene que crear una cuenta en Kaggle como se observa en la Figura 4-5.

Figura 4-5. Cuenta de Kaggle.

The screenshot shows a Kaggle user profile for 'GONZALO ENRIQUE MARTINEZ OJEDA', who joined 2 months ago. The main content is a post by 'Harsh Jhunjhunwala' about a dataset titled 'Water Pollution Data (WHO/UNICEF) | 2000-2021'. The dataset is described as 'World Health Organisation | #TeamSeas' and contains 60 files. Three files are listed: 'Aus_house.xlsx' (14 tables, 3.3 MB), 'Aus_school.xlsx' (11 tables, 1.6 MB), and 'JMP_2020_WinHCF_AFG_Afghanistan.xlsx' (12 tables, 4.9 MB). On the right, there is a 'Novice' skill level section with progress indicators for 'Run 1 notebook or script', 'Make 1 competition or task submission', 'Make 1 comment', and 'Give 1 upvote'. At the bottom right, there is a 'Documentation' section with links for 'Our Team', 'Terms', 'Privacy', 'Contact/Support', and 'Community Guidelines'.

Fuente: propia del estudio

En la página web de Kaggle se encuentra un apartado denominado API, se debes descargar para que se pueda conectar con Google Colab y así se pueda utilizar el Dataset de escoliosis “Starter: Types of Scoliosis 50904dd4-0”. (Figura 4–6).

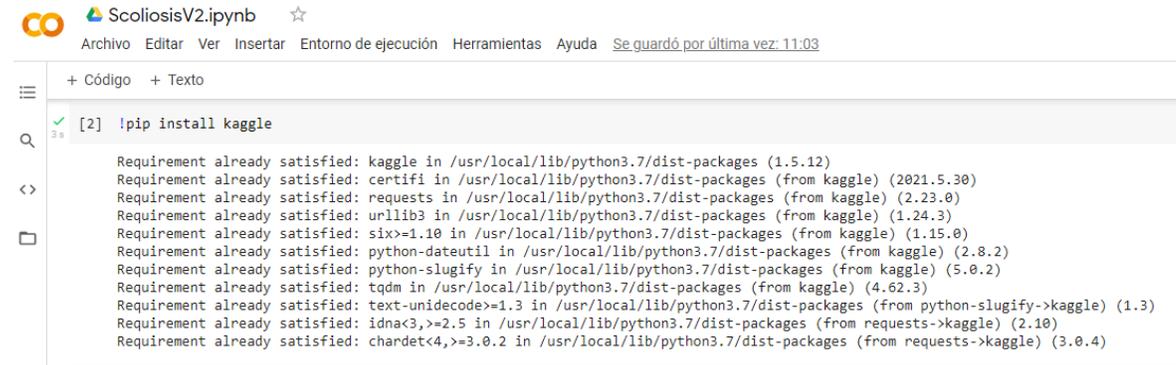
Figura 4-6. Descarga de API.

The screenshot shows the 'Cuenta' (Account) page on Kaggle. The top navigation bar includes 'Hogar', 'Competiciones', 'Conjuntos de datos', 'Código', 'Discusión', 'Seguidores', 'Notificaciones', 'Cuenta', and 'Editar perfil público'. The main content area is titled 'Preferencias de correo electrónico' and includes a link to 'página de configuración de notificaciones'. Below this is the 'API' section, which states: 'Con la API beta de Kaggle, puede interactuar con competencias y conjuntos de datos para descargar datos, realizar envíos y más a través de la línea de comandos. Leer los documentos'. There are two buttons: 'Crear nuevo token de API' and 'Caducar token de API'. At the bottom, there is a 'Cuota' (Quota) section with three rows: 'Datos' (0 B / 107,37 GB), 'privados GPU' (00:00 / 38 hrs), and 'TPU' (00:00 / 30 hrs). Each row has a progress bar and a question mark icon.

Fuente: propia del estudio

Se descarga un archivo .json, posteriormente en Google Colab en el cuaderno **ScoliosisV2.ipynb** se agrega el siguiente código y se corre (Figura 4–7).

Figura 4-7. Instalación API en Colab.



```

ScoliosisV2.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardó por última vez: 11:03

+ Código + Texto

[2] !pip install kaggle

Requirement already satisfied: kaggle in /usr/local/lib/python3.7/dist-packages (1.5.12)
Requirement already satisfied: certifi in /usr/local/lib/python3.7/dist-packages (from kaggle) (2021.5.30)
Requirement already satisfied: requests in /usr/local/lib/python3.7/dist-packages (from kaggle) (2.23.0)
Requirement already satisfied: urllib3 in /usr/local/lib/python3.7/dist-packages (from kaggle) (1.24.3)
Requirement already satisfied: six>=1.10 in /usr/local/lib/python3.7/dist-packages (from kaggle) (1.15.0)
Requirement already satisfied: python-dateutil in /usr/local/lib/python3.7/dist-packages (from kaggle) (2.8.2)
Requirement already satisfied: python-slugify in /usr/local/lib/python3.7/dist-packages (from kaggle) (5.0.2)
Requirement already satisfied: tqdm in /usr/local/lib/python3.7/dist-packages (from kaggle) (4.62.3)
Requirement already satisfied: text-unidecode>=1.3 in /usr/local/lib/python3.7/dist-packages (from python-slugify->kaggle) (1.3)
Requirement already satisfied: idna<3,>=2.5 in /usr/local/lib/python3.7/dist-packages (from requests->kaggle) (2.10)
Requirement already satisfied: chardet<4,>=3.0.2 in /usr/local/lib/python3.7/dist-packages (from requests->kaggle) (3.0.4)

```

Fuente: propia del estudio

Se agrega un directorio donde se encuentran las imágenes a tratar desde Google Drive (Figura 4–8)

Figura 4-8. Directorio de Google Drive base de datos.



```

ScoliosisV2.ipynb
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se guardaron todos los cambios

+ Código + Texto

from google.colab import drive
drive.mount('/content/gdrive')

Mounted at /content/gdrive

[4] import os
os.environ['KAGGLE_CONFIG_DIR'] = "/content/gdrive/MyDrive/Kaggle/Scoliosis"

[5] %cd /content/gdrive/MyDrive/kaggle/Scoliosis

/content/gdrive/MyDrive/kaggle/Scoliosis

```

Fuente: propia del estudio

4.2.1.1 Acondicionamiento.

Hay muchas maneras de ingresar datos en una RNC, ejemplo: en cada paso de ejecución, cargue los datos, precargue los datos en variables y genere un archivo que contenga las imágenes para cargarlas más tarde. Cargar una imagen en cada paso de ejecución tiene el problema de ralentizar el proceso de lectura de grandes cantidades de datos. La precarga de datos en variables solo se usa para conjuntos de datos pequeños porque tiene un límite de carga de memoria y significa sobrecarga y causa problemas en el proceso. La forma más común de manejar una gran cantidad de imágenes es crear un archivo que contenga las imágenes y luego cargarlo como se muestra en la figura 4-7. Por qué es el método de elección para realizar experimentos.

Para el acondicionamiento de las imágenes se agregan las imágenes a tratar, las imágenes se cargan en 2 vectores $X []$, $Y []$ para el conjunto de imágenes de test de escoliosis tipo S y tipo C, $X1 []$, $Y1 []$ para el conjunto de imágenes de test, se redimensiona las imágenes para que todas las imágenes que entren a la RNC tengan las mismas dimensiones que son: (244, 244) pixeles el código que se utiliza para redimensionar se muestra en la (Figura 4-9), y se repite el mismo proceso para el conjunto de imágenes de validación (Figura 4-11).

Figura 4-9. Reasignar y redimensionar.

```
[6] os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/training_set/s')
X = []
y = []
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img, (224, 224))
    X.append(img)
    y.append((i[0:1]))
os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/training_set/c')
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img, (224, 224))
    X.append(img)
for i in range(1, 26):
    y.append('c')

os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/training_set/n')
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img, (224, 224))
    X.append(img)
for i in range(1, 26):
    y.append('n')
```

Nota: se muestra la carga de las carpetas que contienen los respectivos data set de cada conjunto de imágenes para posteriormente ser redimensionados. propia del estudio

Figura 4-10. Imágenes redimensionadas



Nota: se muestra un conjunto de imágenes ya redimensionadas de 224x224.

Figura 4-11. Reasignar y redimensionar.

```

▶ os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/test_set/s')
X1= []
y1 = []
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img,(224,224))
    X1.append(img)
    y1.append((i[0:1]))
os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/test_set/c')
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img,(224,224))
    X1.append(img)
for i in range(1,26):
    y1.append('c')

os.chdir('/content/gdrive/MyDrive/Kaggle/Scoliosis/test_set/n')
for i in tqdm(os.listdir()):
    img = cv2.imread(i)
    img = cv2.resize(img,(224,224))
    X1.append(img)
for i in range(1,26):
    y1.append('n')

```

Nota: se muestra la carga de las carpetas que contienen los respectivos data set de cada conjunto de imágenes para posteriormente ser redimensionados.

Se separan las imágenes con el comando Split, imágenes de test e imágenes de entrenamiento (Figura 4–12).

Figura 4-12. Separación de imágenes

```

▶ X_train, X_test, y_train, y_test = train_test_split(X, y)
print ("Shape of an image in X_train: ", X_train[0].shape)
print ("Shape of an image in X_test: ", X_test[0].shape)

```

↳ Shape of an image in X_train: (224, 224, 3)
 Shape of an image in X_test: (224, 224, 3)

Fuente: propia del estudio

4.2.1.2 Asignación de clases.

Para la escoliosis tipo 'C=0', escoliosis tipo 'S=1', para pacientes sanos "2" luego de asignar donde se encuentran los tipos de escoliosis se les asignan unas variables categóricas como es generar un vector de dos posiciones.

Figura 4-13. Asignación de clases.

```
[ ] X_train=np.array(X)
    y_train=np.array(y)
    X_test=np.array(X1)
    y_test=np.array(y1)
    le = preprocessing.LabelEncoder()
    y_train = le.fit_transform(y_train)
    y_test = le.fit_transform(y_test)
    y_train = tf.keras.utils.to_categorical(y_train, num_classes=3)
    y_test = tf.keras.utils.to_categorical(y_test, num_classes=3)
```

Nota: se muestra la asignación de clases de los conjuntos de imágenes de test y de entrenamiento.

4.2.2 Estructura de la red convolucional.

Para la construcción de la red convolucional se evaluaron diferentes métodos de clasificación, métodos de optimización, las arquitecturas, los frameworks y los diferentes algoritmos.

4.2.2.1 Métodos de clasificación

La clasificación supervisada es una de las tareas más comunes que realizan los llamados "sistemas de inteligencia artificial" para problemas de clasificación, ya que utilizan algoritmos que, a su vez, utilizan datos "históricos" para el problema de clasificación. Por ejemplo, puede "aprender" a asignar la etiqueta de salida adecuada al nuevo valor, es decir, puede predecir el valor de salida. Por ello, los que se han encontrado utilizados previamente en artículos publicados son:

- **Análisis Discriminante Lineal (LDA)**

La técnica LDA se desarrolla para transformar las características en un espacio dimensional de bajo nivel, lo cual maximiza la relación de la variación entre las clases con la variación dentro de la clase, lo cual garantiza la máxima separabilidad de clases.

El objetivo de esta técnica es proyectar la matriz de datos original en un espacio inferior y que, para esto, se necesitan de 3 pasos fundamentales:

1. Calcular la separabilidad entre clases, es decir, la distancia entre los medios de diferentes clases, lo que es llamado el “entre-clase” o “matriz entre clases” (Tharwat, Gaber, Ibrahim, & Hassanien, 2017).

2. Calcular la distancia entre la media y las muestras de cada clase (varianza) dentro de la clases o matriz dentro de la clase (Tharwat, Gaber, Ibrahim, & Hassanien, 2017).

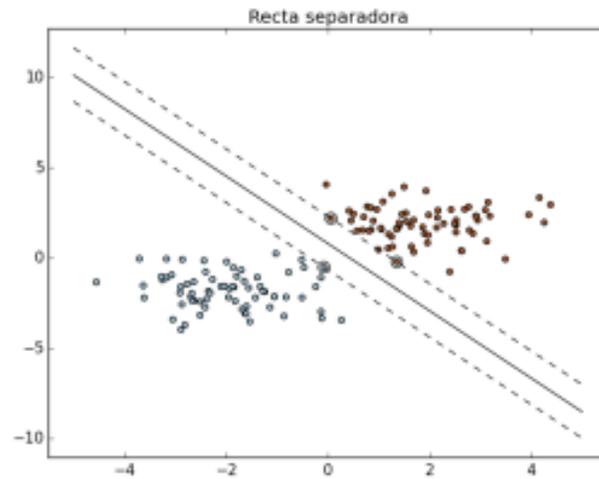
3. Construir el espacio dimensional inferior que maximiza la variación entre clases y minimiza la variación de estas mismas (Tharwat, Gaber, Ibrahim, & Hassanien, 2017).

A pesar de que la técnica LDA se considera una de las técnicas de reducción más utilizadas, sufre de un número de problemas, como, por ejemplo, que el LDA no logra encontrar el espacio dimensional inferior, si las dimensiones son mucho mayores que el número de muestras de datos de la matriz; el otro problema, es el de la linealidad, ya que, si las diferentes clases son separables de forma no lineal, esta técnica no puede discriminar entre clases (Tharwat, Gaber, Ibrahim, & Hassanien, 2017).

- **Máquina de vector soporte (SVM)**

Las máquinas de vectores de soporte son técnicas de aprendizaje automático bien conocidas para la clasificación y otras actividades de aprendizaje y se definen como clasificadores discriminativos que se caracterizan formalmente por un hiperplano óptimo. Esto produce resultados de hiperplano óptimos que clasifican nuevos ejemplos, y los conjuntos de datos que respaldan este hiperplano se denominan vectores de soporte (Battineni, Chintalapudi & Amenta, 2019).

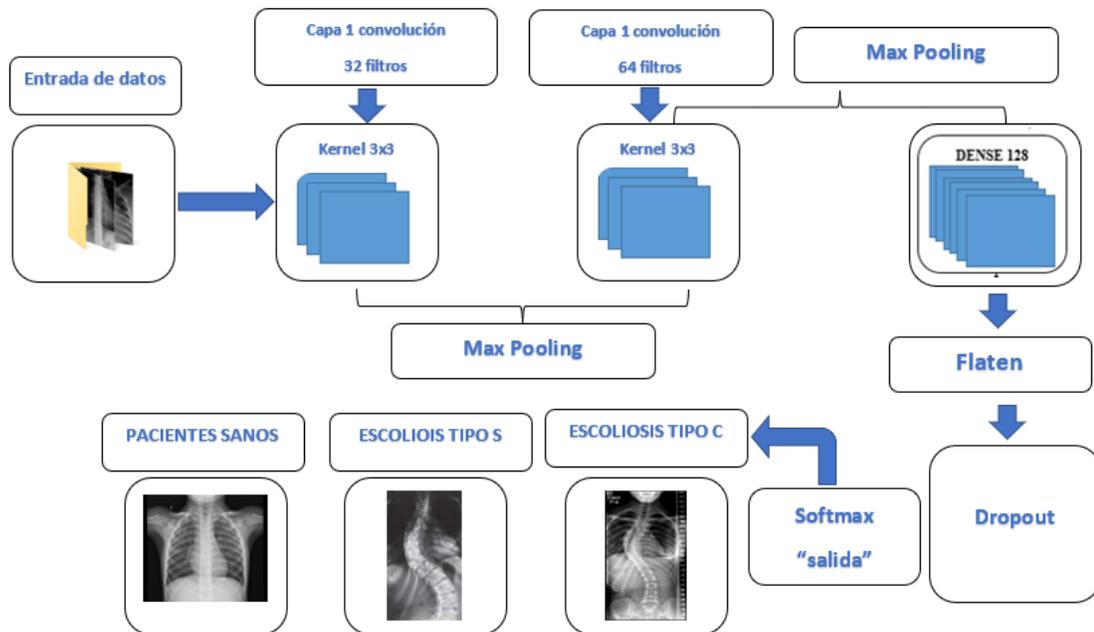
Figura 4-14 Maquina de vector soporte



Nota: se muestra la función de la SVM que aísla los datos de dos dimensiones.

Para nuestro algoritmo de clasificación se utilizó redes neuronales convolucionales (RNC), como se demostró en el capítulo 3 sus principales características a continuación se muestran como estará diseñada nuestra RNC en la Figura 4-15

Figura 4-15. Arquitectura de red convolucional 2 capas.



Fuente: propia del estudio

En la Figura 4–15 se muestra la red empleada en nuestro proyecto donde el siguiente el esquema:

1. **Capa convolucional:** se agrega la primera capa convolucional de 32 filtros convolución con un kernel de tamaño 3x3 y con una función de activación relu.
2. **Muestreo:** se reduce la dimensión de las imágenes convolucionadas con la función maxpooling2d con un tamaño de 2x2.
3. **Capa convolucional:** se agrega la segunda capa convolucional de 64 filtros de convolución con un kernel de tamaño 3X3 y con una función de activación Relu.
4. **Muestreo:** se reduce la dimensión de las imágenes convolucionadas con la función maxpooling2d con un tamaño de 2x2.
5. **Función de aplanación:** los píxeles de las imágenes convolucionadas se ubican en un vector de una sola dimensión utilizando el comando flatten.

6. **Convergencia:** para mejorar la convergencia de la red se desactivan el 50% de las neuronas al azar, para esto se utiliza la función dropout.
7. **Capa feebforward:** red de 128 neuronas con función de activación Relu y 3 neuronas de salida con función de activación Softmax que se conecta con la última capa de muestreo.

Figura 4-16. Red convolucional 2 capas Google Colab.

```
[14] model = Sequential()
      #1 capa convolucional con activación de unidad lineal rectificada
      model.add(Convolution2D(32, kernel_size=(3, 3),
                              activation='relu',
                              input_shape=(224,224,3)))
      #32 filtros de convolución usados cada uno de tamaño 3x3
      #se elige las mejores características a través de la agrupación
      model.add(MaxPooling2D(pool_size=(2, 2)))
      #2 capa convolucional con activación de unidad lineal rectificada
      model.add(Convolution2D(64, kernel_size=(3, 3), activation='relu'))
      #64 filtros de convolución usados cada uno de tamaño 3x3
      #se elige las mejores características a través de la agrupación
      model.add(MaxPooling2D(pool_size=(2, 2)))
      #aplanar ya que hay demasiadas dimensiones, solo queremos una salida de clasificación
      model.add(Flatten())
      model.add(Dense(128, activation='relu'))
      #activa y desactiva las neuronas al azar para mejorar la convergencia
      model.add(Dropout(0.5))
      #output a softmax to squash the matrix into output probabilities
      model.add(Dense(2, activation='softmax'))
```

Fuente: propia del estudio

4.2.2.2 Parámetros de compilación.

Para la compilación de la red neuronal convolucional, proceso donde se entrenan los pesos y los bias de las neuronas es necesario configurar la función de pérdida `Categorical_crossentropy`, el optimizador que para este caso se utilizó el Adam y las métricas para estimar la función de la red neuronal utilizando Accuracy con los datos de test. En la Figura 4-17 se muestra los parámetros que se configuraron para la compilación de la red.

Figura 4-27. Parámetros para la compilación de la red.

```

▶ model.compile(loss='categorical_crossentropy',
               optimizer='adam',
               metrics=['accuracy'])

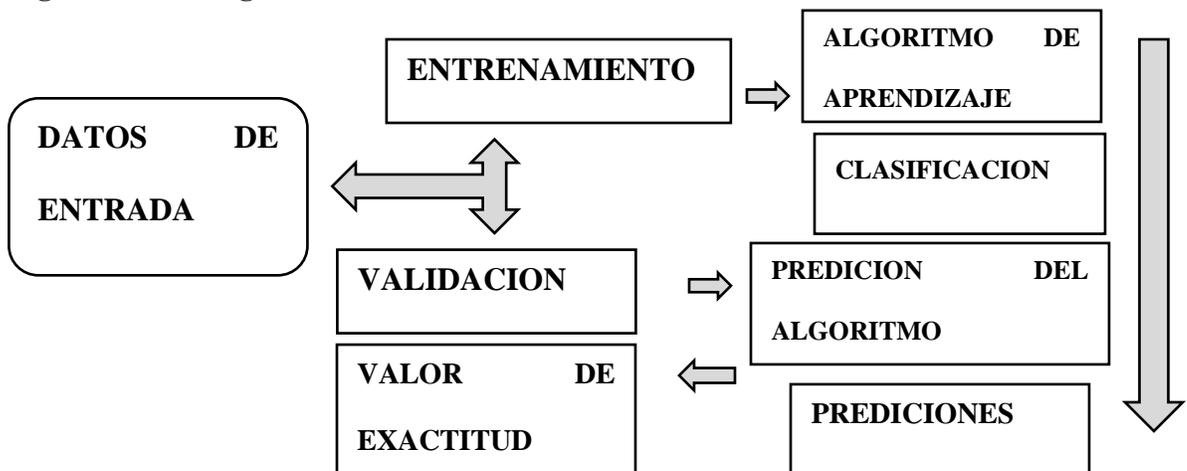
```

Fuente: propia del estudio

4.2.3 Entrenamiento y validación de la red convolucional.

Se sigue el esquema que se muestra en la Fig. 4–18, donde los datos son entrenados por un algoritmo de entrenamiento definido por cada clase, con un descenso de gradiente aleatorio aplicado (Núñez, 2016). Una vez que el modelo aprende los pesos, el algoritmo de predicción ordena los datos de validación según el aprendizaje. La evaluación final del modelo se realiza comparando las predicciones con los datos de verdad de referencia, Las redes convolucionales son dependientes de que exista una gran cantidad de datos de entrenamiento, esto complejiza su aprendizaje y conlleva una gran cantidad de parámetros y la función de pérdida sea no convergente.

Figura 4-38. Diagrama de entrenamiento.



Fuente: propia del estudio

Para el entrenamiento de la red se tomaron lotes de 5 imágenes con un número de 100 épocas como lo muestra la Figura 4–19, obteniendo un Accuracy del 93%, el número del lote

de imágenes y del número de entrenamiento se muestra por qué se utiliza esta cantidad para el entrenamiento en el capítulo 3.1.16

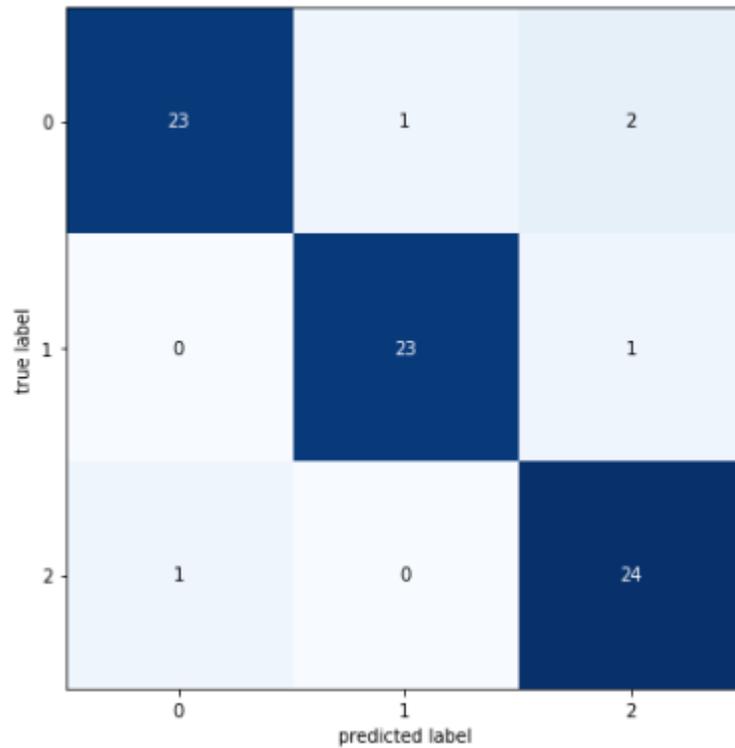
Figura 4-49. Entrenamiento de la red convolucional.

```
▶ batch_size = 5
  num_epoch = 100
  model_log = model.fit(X_train, y_train,
                       batch_size=batch_size,
                       epochs=num_epoch,
                       verbose=1,
                       validation_data=(X_test, y_test))
```

Fuente: propia del estudio

4.2.4 Validación de la red.

El proceso de validación corresponde principalmente a la construcción de una matriz de confusión, también conocida como matriz de errores, que es una tabla resumen que se utiliza para evaluar el desempeño de un modelo de clasificación. El número de predicciones verdaderas y falsas se agrupa con numerología y se divide por categoría. Luego, se generarán tablas para medir el desempeño del clasificador de modelos en la validación del conjunto de los dataset (Figura 4–20).

Figura 4-20. Matriz de confusión.

Nota: se muestra la matriz de confusión multiclase, una matriz de confusión ideal es cuando los falsos positivos, y falsos negativos sean 0.

Donde:

0= escoliosis tipo C.

1= escoliosis tipo S.

2= pacientes sanos.

Tabla 4-2. Tabla de confusión.

MATIZ DE OBSERVACION				
CLASES	MEDIDAS			
	VP	VN	FP	FN
0-ESCOLIOSIS TIPO C	23	48	1	3
1-ESCOLIOSIS TIPO C	23	50	1	1
2-PACIENTES SANOS	24	47	3	1

Nota: se muestra la interpretación de los datos de la matriz de confusión.

Los valores de VN se obtiene de la siguiente manera:

Tabla 4-3. Tabla para obtener los VN.

<p>A 3x3 confusion matrix for Class 0. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in green. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>	<p>A 3x3 confusion matrix for Class 1. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in purple. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>	<p>A 3x3 confusion matrix for Class 2. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in yellow. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>
Clase 0	Clase 1	Clase 2
se obtiene sumando los valores excepto el recuadró de color de verde	se obtiene sumando los valores excepto el recuadró de color morado	se obtiene sumando los valores excepto el recuadró de color amarillo

Nota: se muestra cómo se obtiene los verdaderos negativos.

Tabla 4-4. Tabla para obtener los FP.

<p>A 3x3 confusion matrix for Class 0. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in green. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>	<p>A 3x3 confusion matrix for Class 1. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in purple. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>	<p>A 3x3 confusion matrix for Class 2. The y-axis is 'true label' (0, 1, 2) and the x-axis is 'predicted label' (0, 1, 2). The diagonal elements (0,0), (1,1), and (2,2) are highlighted in yellow. The values are: (0,0)=23, (0,1)=1, (0,2)=0; (1,0)=0, (1,1)=23, (1,2)=24; (2,0)=1, (2,1)=0, (2,2)=24.</p>
Clase 0	Clase 1	Clase 2
se obtiene sumando los valores del recuadró de color de verde excepto el valor que encabeza la columna	se obtiene sumando los valores del recuadró de color de morado excepto el valor que inferior de la columna	se obtiene sumando los valores del recuadró de color amarillo excepto el valor que inferior de la columna

Tabla 4-5. Tabla para obtener los FN.

Clase 0	Clase 1	Clase 2
se obtiene sumando los valores del recuadro de color de verde excepto el valor que encabeza la fila	se obtiene sumando los valores del recuadro de color de morado excepto el valor que central	se obtiene sumando los valores del recuadro de color amarillo excepto el valor que inferior de la fila

La matriz de confusión es una de las formas de medir más simples que posibilita compendiar la productividad de un algoritmo de clasificación. Primero se resuelve el problema de clasificación en el que se predice si una paciente tiene escoliosis tipo “S” o tipo “C” y luego se investiga la matriz de confusión y lo que comunica.

Para realizar los cálculos referentes a los valores obtenidos en la matriz de confusión tendremos que asignar unas variables como son: 1 son los pacientes tienen escoliosis tipo “C”, 0 si los pacientes tienen escoliosis tipo “S”.

Se espera que no existan ni falsos positivos ni falsos negativos.

4.2.4.1 Accuracy.

La precisión en los problemas de clasificación corresponde al número de predicciones correctas hechas por el modelo sobre el total de predicciones de la matriz de confusión:

$$AC = \frac{VN + VP}{VP + VN + FN + FP} * 100 \quad (11)$$

Donde:

AC= Accuracy(exactitud)

VN= verdaderos negativos

VP= verdaderos positivos

FN= falsos negativos

FP= falsos positivos

$$AC0 = \frac{48 + 23}{23 + 48 + 1 + 3} * 100 \quad (6)$$

Donde:

AC0= Accuracy de la clase 0(exactitud)

AC0=95% de exactitud para la clasificación de escoliosis tipo C

$$AC1 = \frac{50 + 23}{23 + 50 + 1 + 1} * 100 \quad (7)$$

Donde:

AC1= Accuracy de la clase 1(exactitud)

AC1=97,3% de exactitud para la clasificación de escoliosis tipo S

$$AC1 = \frac{47 + 24}{24 + 47 + 1 + 3} * 100 \quad (8)$$

Donde:

AC2= Accuracy de la clase 2(exactitud)

AC2=95% de exactitud para la clasificación de escoliosis tipo S exactitud

4.2.4.2 Precisión.

La precisión es una medida que indica el porcentaje de pacientes son diagnosticados con escoliosis. Los predictores positivos fueron los pacientes con escoliosis: VP y FP, mientras que los pacientes que ya tenían escoliosis tipo 'C' VP. Puede extrapolarse a imágenes de huesos y músculos. Matemáticamente, la aritmética se deriva de:

$$PC = \frac{VP}{VP + FP} * 100 \quad (12)$$

Donde:

PC= Precisión

VP= verdaderos positivos

FP= falsos positivos

$$PC0 = \frac{23}{23 + 1} * 100 \quad (10)$$

Donde:

PC0= Precisión clase 0

PC0=96% precisión para clasificar escoliosis tipo C

$$PC1 = \frac{23}{23 + 1} * 100 \quad (11)$$

Donde:

PC1= Precisión clase 1

PC1=96% precisión para clasificar escoliosis tipo S

$$PC2 = \frac{24}{24 + 1} * 100 \quad (10)$$

Donde:

PC2= Precisión clase 2

PC2=96% precisión para clasificar escoliosis tipo C

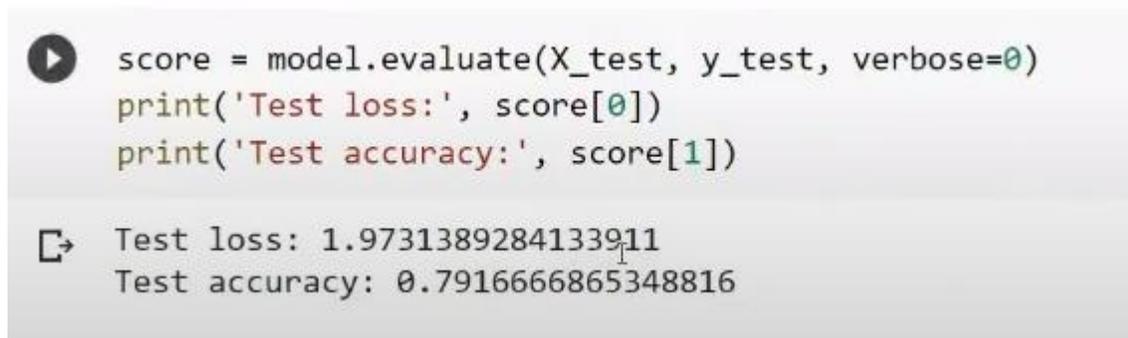
Este indicador se define como el número total de verdaderos positivos en el número total de positivos. Es decir, todo lo que el algoritmo declara positivo se define para compararlo con el número total real de resultados positivos. Equipo de prueba.

CAPÍTULO 5. RESULTADOS Y DISCUSIONES

En este capítulo se exponen los resultados obtenidos después de haber realizado todas las etapas de construcción de la RNC para la clasificación de pacientes con escoliosis tipo C y tipo S, se encuentran las observaciones finales, para el conjunto de datos, con el que fue entrenado, El entrenamiento del modelo requirió un total de 75 imágenes individuales. El tiempo de ejecución para la fase de entrenamiento del modelo fue de 10 minutos.

Los resultados experimentales del algoritmo primeramente presento dificultades en la clasificación cuando solo clasifiqué 2 clases escoliosis tipo C y tipo S, sin embargo, tuvo un porcentaje de clasificación de 79.2% como se muestra en la figura 5.1, luego de que se implementó otra clase de pacientes sanos el porcentaje de clasificación fue del 94%

Figura 5-1. Precisión algoritmo 1.



```

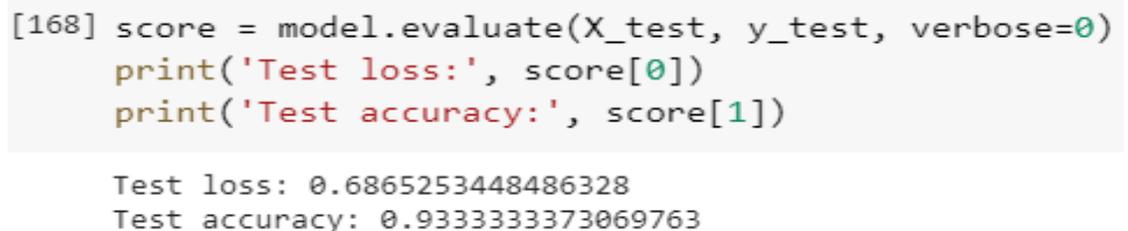
▶ score = model.evaluate(X_test, y_test, verbose=0)
  print('Test loss:', score[0])
  print('Test accuracy:', score[1])

↳ Test loss: 1.9731389284133911
   Test accuracy: 0.7916666865348816

```

Nota: precisión del primer algoritmo de clasificación de 2 clases.

Figura 5-2. Precisión algoritmo 2.



```

[168] score = model.evaluate(X_test, y_test, verbose=0)
      print('Test loss:', score[0])
      print('Test accuracy:', score[1])

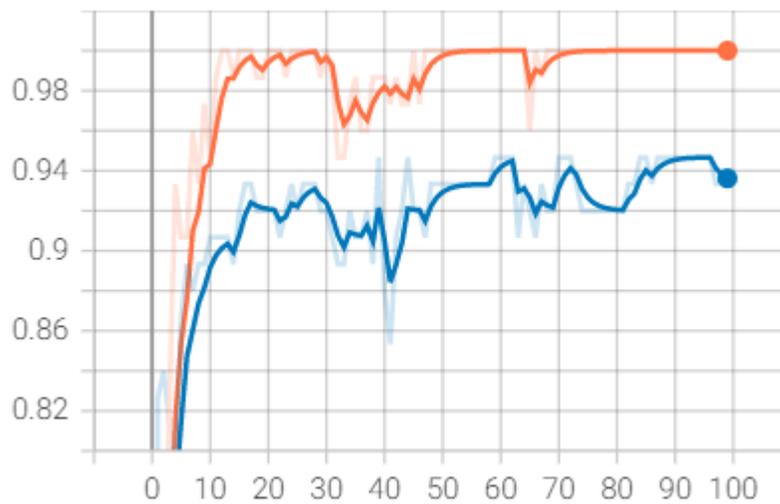
      Test loss: 0.6865253448486328
      Test accuracy: 0.9333333373069763

```

Nota: precisión del primer algoritmo de clasificación de 2 clases.

También se obtuvieron graficas de comparación de Épocas_Accuracy y se obtuvo que el sistema tiene una precisión aceptable como se puede ver en la figura 5-3.

Figura 5-3. Épocas_Accuracy.



Nota: comparación de Épocas_Accuracy del clasificador.

CAPÍTULO 6. CONCLUSIONES Y RECOMENDACIONES

Con ayuda del comité de ética hospitalaria conformado por el técnico de rayos x, especialista en ortopedia, fisioterapeuta, especificado en la sección 4.1.5, se comprobó que el clasificador tiene un porcentaje de precisión del 93% validándolo con las imágenes dadas por el comité del hospital.

Considerando el número reducido de imágenes que tiene la base de datos de Kaggle, fue necesario ampliar la base de datos y tener imágenes de pacientes normales a través del radiológico del HSCJ y de esta manera poder ampliar y construir las bases de datos para entrenamiento y prueba para entrenar y validar la red neuronal convolucional implementada.

Se implementó una red neuronal convolucional en Python utilizando google Colab porque en las capas de convolución se obtienen las características desde las imágenes sin procesamiento, que se utilizan como descriptores para entrenar una red profunda, facilitando de esta manera la clasificación de los tipos de escoliosis S y C e imágenes de pacientes normales.

Se pudo validar el algoritmo entrenado utilizando métricas como la exactitud y matriz de confusión utilizando imágenes de RX obtenidas de una muestra de pacientes sanos y pacientes con escoliosis del “Hospital Sagrado Corazón de Jesús”, la validación del algoritmo fue exitosa dado de la clasificación de pacientes con escoliosis tipo C, el valor de exactitud (Accuracy) es del 95%, para pacientes con escoliosis tipo S es del 97,3%, y para pacientes sanos el valor de exactitud es del 95%.

REFERENCIAS

- Adolescent Idiopathic Scoliosis | Scoliosis Research Society. (s. f.). Scoliosis Research Society. <https://www.srs.org/patients-and-families/conditions-and-treatments/parents/scoliosis/adolescent-idiopathic-scoliosis>
- Amari, S., Murata, N., Muller, K. R., Finke, M., & Yang, H. H. (1997). Asymptotic statistical theory of overtraining and cross-validation. *IEEE Transactions on Neural Networks*, 8(5), 985–996. <https://doi.org/10.1109/72.623200>
- Aramendi, A. R. (2018/2019). *Estudio observacional de las características físicas de las personas con escoliosis, según los criterios del ángulo de rotación del tronco, comparado con un grupo control, en una población escolar*. [Universidad de Zaragoza]. <https://zagan.unizar.es/record/102048?ln=es>
- Artola Moreno, Á. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python [Trabajo de grado no publicado]. Universidad de Sevilla.
- Campaña Jiménez, M. E. (2020). Scoliosis and physical activity in primary school students. *ESHPA - Education, Sport, Health and Physical Activity*, 5(3), 178–192. <https://doi.org/10.5281/ZENODO.4241290>
- Bisong, E. (2019). Google Colaboratory. En *Building Machine Learning and Deep Learning Models on Google Cloud Platform* (pp. 59–64). Apress.
- Chanampe, H., Aciar, S., Vega, M. de la, Molinari Sotomayor, J. L., Carrascosa, G., & Lorefice, A. (2019). Modelo de redes neuronales convolucionales profundas para la clasificación de lesiones en ecografías mamarias. XXI Workshop de Investigadores en Ciencias de la Computación (WICC 2019, Universidad Nacional de San Juan).
- Consenso de escoliosis idiopática del adolescente Autor: Comité Nacional de Adolescencia SAP, Comité de Diagnóstico por Imágenes SAP, Sociedad Argentina de Ortopedia y Traumatología Infantil (SAOTI) Sociedad Argentina de Patología de la Columna Vert. (s/f). Codajic.org. Recuperado el 10 de enero de 2022, de <http://www.codajic.org/node/2218>

- Cunin, V., & Raux, S. (2021). Escoliosis idiopática en período de crecimiento. *EMC - Pediatría*, 56(3), 1–38. [https://doi.org/10.1016/s1245-1789\(21\)45481-8](https://doi.org/10.1016/s1245-1789(21)45481-8)
- D. Gizlyk. “Redes neuronales: así de sencillo (parte 12): Dropout. 2021. Disponible en <https://www.mql5.com/es/articles/9112>
- E. Acevedo, A. Serna, E. Serna. “Principios y características de las redes neuronales artificiales”. In *Desarrollo e innovación en ingeniería*. E. Serna. IAI: Medellín, Colombia, 2017, pp. 173–182.
- Feng, Z., Sun, Z., & Jin, L. (2016). Learning deep neural network using max-margin minimum classification error. 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).
- Flores. (2017). Prediciendo la Actividad Cardíaca de la Almeja *Tivela stultorum* con Digoxina Utilizando Redes Neuronales Artificiales. *Revista Mexicana de Ingeniería Biomédica*.
- Google. “Colaboratory: Frequently Asked Questions”. 2018. Disponible: <https://research.google.com/colaboratory/faq.html>
- Guerrero Moreno, I. R., & Guáqueta Anzola, J. P. (2016). Herramienta de apoyo diagnóstico para detección de malformaciones en columna. <https://repository.javeriana.edu.co/handle/10554/21448>
- Hernández, Emmanuel & Rodríguez Rangel, Héctor & González Huitròn, Víctor Alejandro & Flores, Juan & Puig, Vicenç. (2019). Optimización Distribuida de Redes Convolucionales para la Clasificación de Imágenes. *Research in Computing Science*. 148. 213-226. 10.13053/racs-148-7-16.
- I. Alonso Antón. “Efectividad de los ejercicios de Schroth versus ejercicios de core en la escoliosis”. Trabajo de grado, E.U. Gimbernat Cantabria. 2020.
- J. P. Horne, R. Flannery & S. Usman. “Adolescent idiopathic scoliosis: diagnosis and management. *American Family Physician*, vol. 89, no. 3, 2016.
- Jiménez de las Heras, S. (2018). Clasificación de imágenes médicas mediante redes convolucionales.
- Karski, T. (2010). Factores biomecánicos en la etiología de las escoliosis denominadas idiopáticas.: Nueva clasificación. Nuevos test clínicos y nuevo tratamiento

- conservador y profilaxis. *Cuestiones de fisioterapia: revista universitaria de información e investigación en Fisioterapia*, 39(2), 13–143. <https://dialnet.unirioja.es/servlet/articulo?codigo=3248677>
- kerneler. (2019, octubre 11). Starter: Types of scoliosis 50904dd4-0. Kaggle.Com; Kaggle. <https://www.kaggle.com/kerneler/starter-types-of-scoliosis-50904dd4-0>
- Lisintuña Molina, J. X. (2015). Prevalencia de escoliosis de columna lumbar, en pacientes de 45 a 70 años con rayos x digital, en la Clínica Cruz Blanca de la Ciudad de Quito, periodo abril del 2014 a diciembre del 2014. <http://www.dspace.uce.edu.ec/handle/25000/6830>
- López Saca, F. (2019). Clasificación de imágenes usando redes neuronales convolucionales [Maestría en Ciencias de la Computación no publicada]. Universidad Autónoma Metropolitana.
- Núñez Sánchez, F. J. (2016). Diseño de un sistema de reconocimiento automático de matrículas de vehículos mediante una red neuronal convolucional [Máster Universitario en Ingeniería Informática no publicada]. universidad de catalunya.
- Pascal Garriga, N. (2020). Escoliosis en adolescentes: comparación entre un tratamiento convencional y un tratamiento de Schroth reforzado por la educación terapéutica.
- Pérez López, A. Y. (2020). Asociación entre estado nutricional y escoliosis en escolares de Trujillo. Universidad Privada Antenor Orrego - UPAO.
- Quispicondor Arteaga, A. J. (2019). Correlación radiográfica entre el método de Cobb y el método de Nash en el diagnóstico de escoliosis en columna dorso lumbar. Hospital nacional dos de mayo. Lima. Junio – julio. Año 2018. Universidad Nacional Mayor de San Marcos.
- Quispilaya Valdez, J., & Recuay Rivera, J. D. (2019). Comparación del método Ferguson y Cobb para la evaluación de la curvatura lumbar en pacientes de 25 a 65 años. Universidad Peruana Los Andes.
- Ramírez-Lluch, N., & Acevedo-Echevarría, J. M. (2018). Deformidad de la caja torácica. *Revista Chilena de Cirugía*, 70(4), 373–381. <https://doi.org/10.4067/s0718-40262018000300373>

- Randles, B. M., Pasquetto, I. V., Golshan, M. S., & Borgman, C. L. (2017). Using the jupyter notebook as a tool for open science: An empirical study. 2017 ACM/IEEE Joint Conference on Digital Libraries (JCDL), 1–2.
- Rodríguez Castello, D. (2017). Extracción de cráneo en imágenes de resonancia magnética del cerebro utilizando una red neuronal convolucional 3D. Universitat Politècnica de Catalunya.
- Romero Rodríguez, C. V. (2019). Reconocimiento de imágenes para detección temprana de alteraciones posturales. Universidad Técnica de Ambato. Facultad de Ingeniería en Sistemas, Electrónica e Industrial. Maestría en Automatización y Sistemas de Control.
- Types of Scoliosis*. (n.d.). Kaggle.com. Retrieved January 23, 2022, from <https://www.kaggle.com/f23296/types-of-scoliosis>
- Vargas, E. V., & Meléndez, C. A. A. (2018). Prevalencia de escoliosis en pacientes con parálisis cerebral en un centro de rehabilitación física infantil del norte de México. *Revista médica de Costa Rica*, 84(625). <http://revistamedicacr.com/index.php/rmcr/article/view/12>
- Villavicencio Valdés, A. A. (2020). Detección de la escoliosis en adolescentes según test postural fisioterapéutico. Baños, 2019. Universidad Nacional de Chimborazo.
- Yang, J., Zhang, K., Fan, H., Huang, Z., Xiang, Y., Yang, J., He, L., Zhang, L., Yang, Y., Li, R., Zhu, Y., Chen, C., Liu, F., Yang, H., Deng, Y., Tan, W., Deng, N., Yu, X., Xuan, X., ... Lin, H. (2019). Development and validation of deep learning algorithms for scoliosis screening using back images. *Communications Biology*, 2(1), 390. <https://doi.org/10.1038/s42003-019-0635-8>
- Zardo, E. D. E. A., Ziegler, M. S., Serdeira, A., Severo, C. M. D., Frast, R. V., Rech, P. R., Toffolo, L., Scalco, R. S., & Schwanke, C. H. A. (2017). Applicability of the Cobb angle measurement in idiopathic scoliosis using scanned imaging. *Coluna/Columna*, 16(1), 22–24. <https://doi.org/10.1590/s1808-185120171601153058>