



**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA**

**FACULTAD DE INGENIERÍA**

**PROYECTO DE INVESTIGACIÓN**

**PREDICCIÓN DE DEFORMIDADES DE LA COLUMNA VERTEBRAL EN IMÁGENES DE  
NEURORRADIOLOGÍA APLICANDO APRENDIZAJE POR TRANSFERENCIA PROFUNDA**

**PREVIO A LA OBTENCIÓN DEL TÍTULO**

**INGENIERO EN BIOMÉDICA**

**PRESENTADO POR:**

**21941112 ARIANA ALEJANDRA ANDREWS INTERIANO**

**21951028 MANUEL ALEJANDRO MARTÍNEZ PALMA**

**ASESOR: KARLA REYES**

**OCTUBRE, 2023**

## DEDICATORIA

Dedico este logro primeramente a Dios por permitirme culminar esta etapa de manera exitosa. A mis papás, por nunca dejarme sola, tomar mi mano y brindarme ese apoyo incondicional. A mi hermana, por siempre ser mi guía y siempre estar ahí para mí. A mi familia por depositar su confianza en mí y motivarme a seguir adelante.

**-Ariana Andrews**

Dedico este trabajo primeramente a Dios, quien ha sido mi constante guía y protector en mi camino hacia esta etapa. Así mismo a mi madre cuyo apoyo, comprensión y amor han sido fundamentales en cada paso que he dado y a mi padre que a pesar de que no pudo acompañarme en esta etapa físicamente, siempre fue mi fuente de inspiración y fortaleza a lo largo de este recorrido.

**-Manuel Martínez**

## **AGRADECIMIENTOS**

Agradezco a Dios por darme las fuerzas y esfuerzo para poder realizar esta tesis a lo largo de este tiempo. A mis papás, por siempre motivarme a salir adelante aún en mis días más difíciles, apoyarme a dar lo mejor de mí en mi día a día y por su amor incondicional. A mi hermana, que a pesar de estar lejos de mí siempre me escuchaba, sos mi modelo a seguir. A mi perrita, por ser mi compañía en cada una de las noches que me acostaba tarde. A mi compañero de tesis, mejor compañero de carrera, uno de mis mejores amigos y mi compañero de desvelo, por siempre estar ahí para mí para explicarme una y otra vez las cosas que no entendía y por compartir tantos momentos altibajos a lo largo de la carrera. A mis mejores amigos cercanos, gracias por estar para mí y por siempre mostrarme esa admiración hacia mi persona. Agradecer a mis docentes, por su pasión por la enseñanza y dedicación. Por último, a mi compañero no de carrera, que a pesar de que no coincidimos en muchas clases, logró acompañarme hasta esta última etapa de la universidad brindándome mucho apoyo y cariño, estaba para mí en las buenas y en las malas a pesar de las adversidades y alentarme a ser mejor persona cada día de mi vida.

**-Ariana Andrews**

Agradezco a Dios por bendecirme y brindarme la sabiduría necesaria para llevar a cabo este proyecto. Agradezco profundamente a mi padre, Teófilo Martínez que a pesar de no poder estar conmigo, dejó una huella importante en mi vida para seguir esforzándome día a día para lograr mis objetivos. Agradezco eternamente a quien le debo todo, a mi madre, Nelly Palma, quién sin importar las adversidades, ha hecho hasta lo imposible para brindarme una excelente educación, me ha forjado, me ha amado y ha sido un pilar fundamental en todo este recorrido. Agradezco a mi hermano Mario Martínez por demostrarme a mí mismo el poder de mis capacidades cuando más lo necesité. A mis tíos Ulises Palma y Linda Lemus y Edgardo Palma, por el cariño y apoyo que me han brindado hasta el momento. Agradezco a mi compañera, y una de las mejores personas que tengo en mi vida Ariana Andrews, por compartir momentos de felicidad, tristeza y estrés a lo largo de este proyecto y la vida universitaria. Por último, agradecer a cada uno de mis amigos que han demostrado su apoyo a lo largo de mi carrera, y a mis docentes que con mucha pasión lograron dejar una semilla de conocimiento en mí persona.

**-Manuel Martínez**

## EPÍGRAFE

*“Lo que con mucho trabajo se adquiere, más se ama.”*

**Aristóteles**

*“Yo no pienso, yo investigo.”*

**Wilhelm Röntgen**

## RESUMEN EJECUTIVO

La columna vertebral es la estructura que brinda soporte, protección y ayuda a la movilización del ser humano. Existen deformaciones de la columna vertebral como la escoliosis y la espondilolistesis que llegan a causar malestares en el paciente. Es por ello, que la detección temprana de estas deformidades por medio de imágenes radiológicas es de suma importancia para prevenir el desarrollo de estas. Hoy en día, existen sistemas que utilizan inteligencia artificial para realizar el proceso de clasificación de manera eficiente. En este caso, se utilizó el aprendizaje de transferencia profunda con modelos pre-entrenados para clasificar las imágenes radiográficas en tres diferentes clases (sin escoliosis, escoliosis y espondilolistesis). La investigación contó con un enfoque cuantitativo, alcance exploratorio y diseño experimental. Por otro lado, la metodología implementada fue la iterativa a través de cuatro incrementos. El primer incremento se enfocó en realizar pruebas y ajuste fino para los modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0. En el segundo incremento se realizaron pruebas y ajuste fino en los modelos EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2. En el tercer incremento, se realizó una base de datos con imágenes médicas de pacientes hondureños. En el cuarto incremento, se realizaron predicciones con los modelos que mejor se desempeñaron. Como consecuencia, se identificó que en el primer incremento se logró una exactitud media de 97.01% y en el segundo incremento se alcanzó una exactitud media de 98.01% en los modelos evaluados. Se consolidó la creación de una base de datos local para su implementación en futuras líneas de investigación y se validó el algoritmo de clasificación mediante predicciones de imágenes radiográficas de pacientes hondureños.

**Palabras claves:** escoliosis, espondilolistesis, exactitud, neurocirugía, radiología

## **ABSTRACT**

The vertebral column is the structure that provides support, protection, and facilitates human mobility. There are vertebral column deformities such as scoliosis and spondylolisthesis that can cause discomfort in patients. Therefore, early detection of these deformities through radiological images is of great importance to prevent their progression. Nowadays, there are systems that use artificial intelligence to efficiently classify these images. In this case, deep transfer learning with pre-trained models was employed to classify radiographic images into three different classes (no scoliosis, scoliosis, and spondylolisthesis). The research followed a quantitative approach, had an exploratory scope, and an experimental design. The methodology implemented was iterative through four increments. The first increment focused on testing and fine-tuning the MobileNetV3-Small, MobileNetV3-Large, and EfficientNetV2B0 models. In the second increment, tests and fine-tuning were conducted on the EfficientNetV2B1, EfficientNetV2B2, and InceptionResNetV2 models. In the third increment, a database of medical images from Honduran patients was created. In the fourth, predictions were made using the best-performing models. As a result, it was found that in the first increment, an average accuracy of 97.01% was achieved, and in the second increment, an average accuracy of 98.01% was reached for the evaluated models. The creation of a local database for future research lines was consolidated, and the classification algorithm was validated through predictions of radiographic images of Honduras patients.

**Key words:** accuracy, neurosurgery, radiology, scoliosis, spondylolisthesis

# ÍNDICE DE CONTENIDO

<b>I.</b>	<b>INTRODUCCIÓN.....</b>	<b>1</b>
<b>II.</b>	<b>PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>3</b>
<b>2.1</b>	<b>PRECEDENTES DEL PROBLEMA .....</b>	<b>3</b>
<b>2.2</b>	<b>DEFINICIÓN DEL PROBLEMA .....</b>	<b>6</b>
<b>2.3</b>	<b>JUSTIFICACIÓN .....</b>	<b>7</b>
<b>2.4</b>	<b>PREGUNTAS DE INVESTIGACIÓN .....</b>	<b>8</b>
2.4.1	PREGUNTA GENERAL.....	8
2.4.2	PREGUNTAS ESPECÍFICAS.....	8
<b>2.5</b>	<b>OBJETIVOS.....</b>	<b>9</b>
2.5.1	OBJETIVO GENERAL .....	9
2.5.2	OBJETIVOS ESPECÍFICOS .....	9
<b>III.</b>	<b>ESTADO DEL ARTE .....</b>	<b>10</b>
<b>3.1</b>	<b>ANÁLISIS DE LA SITUACIÓN ACTUAL.....</b>	<b>10</b>
3.1.1	MACROENTORNO .....	10
3.1.2	MICROENTORNO.....	20
<b>3.2</b>	<b>CONCEPTUALIZACIÓN .....</b>	<b>25</b>
3.2.1	COLUMNA VERTEBRAL .....	25
3.2.2	ESCOLIOSIS .....	26
3.2.3	ESPONDILOLISTESIS.....	31
3.2.4	APRENDIZAJE PROFUNDO.....	34
<b>IV.</b>	<b>METODOLOGÍA .....</b>	<b>45</b>
<b>4.1</b>	<b>ENFOQUE .....</b>	<b>45</b>
<b>4.2</b>	<b>VARIABLES DE INVESTIGACIÓN .....</b>	<b>46</b>
4.2.1	VARIABLES DEPENDIENTES.....	46
4.2.2	VARIABLES INDEPENDIENTES .....	46

<b>4.3</b>	<b>TÉCNICAS E INSTRUMENTOS APLICADOS.....</b>	<b>47</b>
4.3.1	TÉCNICAS.....	47
4.3.2	HERRAMIENTAS.....	51
<b>4.4</b>	<b>MATERIALES.....</b>	<b>52</b>
<b>4.5</b>	<b>METODOLOGÍA DE ESTUDIO.....</b>	<b>55</b>
<b>4.6</b>	<b>METODOLOGÍA DE VALIDACIÓN.....</b>	<b>56</b>
4.6.1	CREACIÓN DE CONJUNTO DE DATOS DE PRUEBA Y VALIDACIÓN.....	56
4.6.2	MATRIZ DE CONFUSIÓN.....	57
4.6.3	ANÁLISIS Y CÁLCULOS NÚMERICOS.....	58
<b>4.7</b>	<b>CRONOGRAMA DE ACTIVIDADES.....</b>	<b>60</b>
<b>4.8</b>	<b>MATRIZ METODOLÓGICA.....</b>	<b>61</b>
<b>4.9</b>	<b>OPERACIONALIZACIÓN DE VARIABLES.....</b>	<b>65</b>
<b>V.</b>	<b>RESULTADOS Y ANÁLISIS.....</b>	<b>71</b>
<b>5.1</b>	<b>INCREMENTO 1: PRUEBAS Y AJUSTE FINO PARA MODELOS PRE-ENTRENADOS: MOBILENETV3-SMALL, MOBILENETV3-LARGE Y EFFICIENTNETV2B0.....</b>	<b>71</b>
<b>5.2</b>	<b>INCREMENTO 2: PRUEBAS Y AJUSTE FINO PARA MODELOS PRE-ENTRENADOS: EFFICIENTNETV2B1, EFFICIENTNETV2B2 E INCEPTIONRESNETV2.....</b>	<b>81</b>
<b>5.3</b>	<b>INCREMENTO 3: RECOLECCIÓN DE DATOS NUEVOS.....</b>	<b>90</b>
<b>5.4</b>	<b>INCREMENTO 4: EVALUACIÓN DE RESULTADOS DE RED.....</b>	<b>91</b>
<b>5.5</b>	<b>DISCUSIÓN DE RESULTADOS.....</b>	<b>94</b>
5.5.1	INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 1.....	94
5.5.2	INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 2.....	99
5.5.3	INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 3.....	104
5.5.4	INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 4.....	106
5.5.5	COMPARATIVA DE RESULTADOS OBTENIDOS CON LOS DEL ESTADO DEL ARTE.....	110
<b>VI.</b>	<b>CONCLUSIONES.....</b>	<b>111</b>

<b>VII. RECOMENDACIONES.....</b>	<b>113</b>
<b>VIII. APLICABILIDAD/IMPLEMENTACIÓN .....</b>	<b>114</b>
<b>IX. TRABAJO FUTURO.....</b>	<b>115</b>
<b>REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>116</b>
<b>ANEXOS .....</b>	<b>124</b>

## ÍNDICE DE ILUSTRACIONES

<b>Ilustración 1- Segmentos de la Columna Vertebral</b> .....	26
<b>Ilustración 2-Paciente con Escoliosis Idiopática</b> .....	27
<b>Ilustración 3-Medición Ángulo de Cobb</b> .....	28
<b>Ilustración 4-El Signo de Risser</b> .....	29
<b>Ilustración 5-Fijación Posterior de Escoliosis</b> .....	30
<b>Ilustración 6-Tipos de Espondilolistesis</b> .....	31
<b>Ilustración 7-Eschema de Clasificación de Espondilolistesis: Meyerding y Taillard</b> .....	33
<b>Ilustración 8-Tratamiento Quirúrgico de la Espondilolistesis</b> .....	34
<b>Ilustración 9-Estructura de una Red Neuronal Convolutacional</b> .....	36
<b>Ilustración 10-Ejemplo de una Convolución</b> .....	39
<b>Ilustración 11-Agrupamiento Tradicional</b> .....	40
<b>Ilustración 12- Aplicación de CNN en Segmentación de Imágenes</b> .....	41
<b>Ilustración 13-Aprendizaje Residual a través de Conexiones de Salto</b> .....	43
<b>Ilustración 14-Estructura de SSD</b> .....	44
<b>Ilustración 15- Variables Dependientes e Independientes</b> .....	47
<b>Ilustración 16- Arquitectura de modelo pre-entrenado MobileNetV3.</b> .....	48
<b>Ilustración 17- Arquitectura de modelo pre-entrenado EfficientNetV2</b> .....	49
<b>Ilustración 18- Arquitectura de modelo pre-entrenado InceptionResNetV2</b> .....	49
<b>Ilustración 19- Proceso de Aprendizaje de Transferencia</b> .....	51
<b>Ilustración 20- Diagrama de flujo del código</b> .....	52
<b>Ilustración 21- Paciente con Espondilolistesis Imagen Kaggle</b> .....	53
<b>Ilustración 22- Paciente con Escoliosis Imagen Kaggle</b> .....	53

<b>Ilustración 23- Paciente Sano Imagen Kaggle .....</b>	<b>53</b>
<b>Ilustración 24- Paciente con Escoliosis Imagen Roboflow.....</b>	<b>54</b>
<b>Ilustración 25- Paciente Sano Imagen Roboflow .....</b>	<b>54</b>
<b>Ilustración 26- Paciente con Espondilolistesis Imagen Roboflow .....</b>	<b>54</b>
<b>Ilustración 27- Esquema de Metodología Incremental o Iterativa.....</b>	<b>55</b>
<b>Ilustración 28- Ejemplo de Matriz de Confusión.....</b>	<b>57</b>
<b>Ilustración 29- Cronograma de Actividades Primer Parcial.....</b>	<b>60</b>
<b>Ilustración 30- Muestra de imágenes para entrenamiento del clasificador de imágenes. .....</b>	<b>72</b>
<b>Ilustración 31- Fragmento de código para predicción #1 .....</b>	<b>92</b>
<b>Ilustración 32- Fragmento de código para predicción #2 .....</b>	<b>93</b>
<b>Ilustración 33- Fragmento de código para predicción #3 .....</b>	<b>94</b>
<b>Ilustración 34- Matriz de confusión de EfficientNetV2B0 con un entrenamiento de 50 épocas y un tamaño de lote de 20.....</b>	<b>96</b>
<b>Ilustración 35- Curvas de aprendizaje de EfficientNetV2B0 con 50 épocas y un tamaño de lote de 20. ....</b>	<b>99</b>
<b>Ilustración 36- Matriz de Confusión de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño de lote de 70.....</b>	<b>101</b>
<b>Ilustración 37-Curvas de aprendizaje de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño del lote de 70. ....</b>	<b>104</b>
<b>Ilustración 38- Reparto de información de radiografías recolectadas en el primer hospital .....</b>	<b>105</b>
<b>Ilustración 39- Reparto de datos de radiografías recolectadas en el segundo hospital .....</b>	<b>105</b>
<b>Ilustración 40- Reparto de datos de radiografías recolectadas en el tercer hospital.</b>	<b>106</b>

<b>Ilustración 41- Predicciones de escoliosis realizadas por EfficientNetV2B0.....</b>	<b>107</b>
<b>Ilustración 42- Predicciones de espondilolistesis realizadas por EfficientNetV2B0....</b>	<b>107</b>
<b>Ilustración 43- Predicciones de columna vertebral sin escoliosis realizadas por EfficientNetV2B0.....</b>	<b>108</b>
<b>Ilustración 44- Predicciones de escoliosis realizadas por EfficientNetV2B2.....</b>	<b>108</b>
<b>Ilustración 45- Predicciones de espondilolistesis realizadas por EfficientNetV2B2....</b>	<b>109</b>
<b>Ilustración 46- Predicciones de columna vertebral sin escoliosis realizadas por EfficientNetV2B2.....</b>	<b>109</b>

## ÍNDICE DE TABLAS

<b>Tabla 1- Resultados de clasificadores con el método de división con una proporción de muestras del 50%. .....</b>	<b>12</b>
<b>Tabla 2- Resultados de método de validación cruzada de diez pliegues. ....</b>	<b>13</b>
<b>Tabla 3- Resultados de exactitud, sensibilidad, especificidad, y precisión, después de usar 20% y 30% de los datos como datos de prueba en el clasificador BA. ....</b>	<b>15</b>
<b>Tabla 4- Comparación de rendimiento de modelos de segmentación de columna vertebral.....</b>	<b>17</b>
<b>Tabla 5- Exactitud de clasificador de radiografías en tres clases; normal, escoliosis y espondilolistesis, para cada modelo de aprendizaje profundo.....</b>	<b>19</b>
<b>Tabla 6- El puntaje F1 promedio general, precisión y sensibilidad, para los catorce modelos de aprendizaje profundo, realizando clasificación de tres clases.....</b>	<b>20</b>
<b>Tabla 7- Resultados de pruebas para dos muestras relacionadas. ....</b>	<b>24</b>
<b>Tabla 8- Resultados de exactitud de las dos versiones del clasificador de imágenes radiográficas a partir de RNC.....</b>	<b>25</b>
<b>Tabla 9- Metodología de Investigación.....</b>	<b>45</b>
<b>Tabla 10- Matriz Metodológica .....</b>	<b>61</b>
<b>Tabla 11- Operacionalización de Variables.....</b>	<b>65</b>
<b>Tabla 12- Comparativa de MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0 con un entrenamiento de 50 épocas. ....</b>	<b>73</b>
<b>Tabla 13- Comparativa de modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0 con un entrenamiento de 75 épocas.....</b>	<b>76</b>
<b>Tabla 14-Comparativa de modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetB0 con un entrenamiento de 100 épocas.....</b>	<b>78</b>

<b>Tabla 15- Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 50 épocas.</b> .....	82
<b>Tabla 16- Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 75 épocas.</b> .....	85
<b>Tabla 17-Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 100 épocas.</b> .....	87
<b>Tabla 18- Configuración y métricas de desempeño alcanzadas en los modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0</b> .....	95
<b>Tabla 19- Matriz de Observación de EfficientNetV2B0 con un entrenamiento de 50 épocas y un tamaño de lote de 20.</b> .....	96
<b>Tabla 20- Configuración y métricas de desempeño alcanzadas en los modelos EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2.</b> .....	100
<b>Tabla 21- Matriz de Observación de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño de lote de 70.</b> .....	101
<b>Tabla 22- Resultados Obtenidos en las Metodologías descritas en el Estado del Arte</b> .....	110

## ÍNDICE DE ECUACIONES

<b>Ecuación 1- Ecuación para calcular el Mapa de Características .....</b>	<b>36</b>
<b>Ecuación 2- Cálculo para encontrar las dimensiones de la capa de agrupación.....</b>	<b>37</b>
<b>Ecuación 3- Función de pérdida.....</b>	<b>37</b>
<b>Ecuación 4- Exactitud para algoritmo de clasificación de imágenes .....</b>	<b>58</b>
<b>Ecuación 5- Precisión para algoritmo de clasificación de imágenes.....</b>	<b>58</b>
<b>Ecuación 6- Sensibilidad de algoritmo de clasificación de imágenes .....</b>	<b>59</b>
<b>Ecuación 7- Puntuaje F1 de algoritmo de clasificación de imágenes .....</b>	<b>59</b>

## ÍNDICE DE ANEXOS

<b>Anexo 1- Matriz de Confusión MobileNetV3-Small, Época 50, Tamaño de Lote 20...</b>	<b>124</b>
<b>Anexo 2- Gráficos de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 20</b> .....	<b>124</b>
<b>Anexo 3- Matriz de Confusión MobileNet V3-Small, Época 50, Tamaño de Lote 50</b>	<b>125</b>
<b>Anexo 4- Gráficas de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 50</b> .....	<b>125</b>
<b>Anexo 5- Matriz de Confusión MobileNet V3-Small, Época 50, Tamaño de Lote 70</b>	<b>126</b>
<b>Anexo 6- Gráficas de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 70</b> .....	<b>126</b>
<b>Anexo 7- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 20</b>	<b>127</b>
<b>Anexo 8- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 20</b> .....	<b>127</b>
<b>Anexo 9- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 50</b>	<b>128</b>
<b>Anexo 10- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 50</b> .....	<b>128</b>
<b>Anexo 11- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 70</b> .....	<b>129</b>
<b>Anexo 12- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 70</b> .....	<b>129</b>
<b>Anexo 13- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote</b> <b>20</b> Fuente: Elaboración Propia .....	<b>130</b>
<b>Anexo 14- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote</b> <b>20</b> .....	<b>130</b>

<b>Anexo 15- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote 50</b> .....	131
<b>Anexo 16- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote 50</b> .....	131
<b>Anexo 17- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote 70</b> .....	132
<b>Anexo 18- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote 70</b> .....	132
<b>Anexo 19- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 20</b> .....	133
<b>Anexo 20- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 20</b> .....	133
<b>Anexo 21- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 50</b> .....	134
<b>Anexo 22- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 50</b> .....	134
<b>Anexo 23- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 70</b> .....	135
<b>Anexo 24- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 70</b> .....	135
<b>Anexo 25- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 20</b> .....	136
<b>Anexo 26- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 20</b> .....	136
<b>Anexo 27- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 50</b> .....	137

<b>Anexo 28- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 50</b>	137
<b>Anexo 29- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 70</b>	138
<b>Anexo 30- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 70</b>	138
<b>Anexo 31- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 20</b>	139
<b>Anexo 32- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote 20</b>	139
<b>Anexo 33- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 50</b>	140
<b>Anexo 34- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote 50</b>	140
<b>Anexo 35- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 70</b>	141
<b>Anexo 36- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote 70</b>	141
<b>Anexo 37- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 20</b>	142
<b>Anexo 38- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 20</b>	142
<b>Anexo 39- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 50</b>	143
<b>Anexo 40- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 50</b>	143
<b>Anexo 41- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 70</b>	144

<b>Anexo 42- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 70</b>	144
<b>Anexo 43- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 20</b>	145
<b>Anexo 44- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 20</b>	145
<b>Anexo 45- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 50</b>	146
<b>Anexo 46- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 50</b>	146
<b>Anexo 47- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 70</b>	147
<b>Anexo 48- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 70</b>	147
<b>Anexo 49- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 20</b>	148
<b>Anexo 50- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 20</b>	148
<b>Anexo 51- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 50</b>	149
<b>Anexo 52- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 50</b>	149
<b>Anexo 53- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 70</b>	150
<b>Anexo 54- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 70</b>	150
<b>Anexo 55- Matriz de Confusión EfficientNetV2B1, Época 50, Tamaño de Lote 20</b>	151
<b>Anexo 56- Gráficas de Desempeño EfficientNetV2B1, Época 50, Tamaño de Lote 20</b>	151
<b>Anexo 57- Matriz de Confusión EfficientNetV2B1, Época 50, Tamaño de Lote 50</b>	152

<b>Anexo 58- Gráficas de Desempeño EfficientNetV2B1, Época 50, Tamaño de Lote 50</b> .....	152
<b>Anexo 59- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 20 ....</b>	153
<b>Anexo 60- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 20</b> .....	153
<b>Anexo 61- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 50 .....</b>	154
<b>Anexo 62- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 50</b> .....	154
<b>Anexo 63- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 70 .....</b>	155
<b>Anexo 64- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 70</b> .....	155
<b>Anexo 65- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 20...</b>	156
<b>Anexo 66- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 20</b> .....	156
<b>Anexo 67- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 50...</b>	157
<b>Anexo 68- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 50</b> .....	157
<b>Anexo 69- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 70...</b>	158
<b>Anexo 70- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 70</b> .....	158
<b>Anexo 71- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 20 .....</b>	159
<b>Anexo 72- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 20</b> .....	159
<b>Anexo 73- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 50 .....</b>	160

<b>Anexo 74- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 50</b>	160
<b>Anexo 75- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 70</b>	161
<b>Anexo 76- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 70</b>	161
<b>Anexo 77- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 20</b>	162
<b>Anexo 78- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 20</b>	162
<b>Anexo 79- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 50</b>	163
<b>Anexo 80- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 50</b>	163
<b>Anexo 81- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 70</b>	164
<b>Anexo 82- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 70</b>	164
<b>Anexo 83- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 20</b>	165
<b>Anexo 84- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 20</b>	165
<b>Anexo 85- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 50</b>	166
<b>Anexo 86- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 50</b>	166
<b>Anexo 87- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 70</b>	167
<b>Anexo 88- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 70</b>	167
<b>Anexo 89- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 20</b>	168

<b>Anexo 90- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 20</b> .....	168
<b>Anexo 91- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 50.</b>	169
<b>Anexo 92- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 50</b> .....	169
<b>Anexo 93- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 70</b>	170
<b>Anexo 94- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 70</b> .....	170
<b>Anexo 95- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 20.</b>	171
<b>Anexo 96- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote 20</b> .....	171
<b>Anexo 97- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 50.</b>	172
<b>Anexo 98- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote 50</b> .....	172
<b>Anexo 99- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 70.</b>	173
<b>Anexo 100- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote 70</b> .....	173
<b>Anexo 101- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 20</b> .....	174
<b>Anexo 102- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote 20.</b> .....	174
<b>Anexo 103- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 50</b> .....	175
<b>Anexo 104- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote 50.</b> .....	175

<b>Anexo 105- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 70</b>	176
<b>Anexo 106- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote 70</b>	176
<b>Anexo 107- Predicciones de Escoliosis de EfficientNetV2B0</b>	177
<b>Anexo 108- Predicciones de Escoliosis y Espondilolistesis de EfficientNetV2B0</b>	178
<b>Anexo 109- Predicciones de Espondilolistesis de EfficientNetV2B0</b>	179
<b>Anexo 110- Predicciones de Espondilolistesis de EfficientNetV2B0</b>	180
<b>Anexo 111- Predicciones de Espondilolistesis y Sin Escoliosis de EfficientNetV2B0</b>	181
<b>Anexo 112- Predicciones de Sin Escoliosis de EfficientNetV2B0</b>	182
<b>Anexo 113- Errores en las predicciones de EfficientNetV2B0</b>	183
<b>Anexo 114- Errores en las predicciones de EfficientNetV2B0</b>	184
<b>Anexo 115- Errores en las predicciones de EfficientNetV2B0</b>	185
<b>Anexo 116- Predicciones de Escoliosis de EfficientNetV2B2</b>	186
<b>Anexo 117- Predicciones de Escoliosis y Espondilolistesis de EfficientNetV2B2</b>	187
<b>Anexo 118- Predicciones de Espondilolistesis de EfficientNetV2B2</b>	188
<b>Anexo 119- Predicciones de Espondilolistesis de EfficientNetV2B2</b>	189
<b>Anexo 120- Predicciones de Espondilolistesis y Sin Escoliosis de EfficientNetV2B2</b>	190
<b>Anexo 121- Predicciones de Sin Escoliosis de EfficientNetV2B2</b>	191
<b>Anexo 122- Errores de Predicción de EfficientNetV2B2</b>	192
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2</b>	192
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2</b>	192

<b>Anexo 123- Errores de Predicción de EfficientNetV2B2Anexo 122- Errores de Predicción de EfficientNetV2B2 .....</b>	<b>192</b>
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2Anexo 122- Errores de Predicción de EfficientNetV2B2 .....</b>	<b>192</b>
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2.....</b>	<b>193</b>
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2.....</b>	<b>193</b>
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2.....</b>	<b>193</b>
<b>Anexo 123- Errores de Predicción de EfficientNetV2B2.....</b>	<b>193</b>
<b>Anexo 124- Errores de Predicción de EfficientNetV2B2.....</b>	<b>194</b>

## LISTA DE SIGLAS

ACP	Análisis de Componente Principal
ADL	Análisis Discriminante Lineal
BA	Bosque Aleatorio
CNN	Convolutional Neuroal Network (Red Neuronal Convolutacional)
ED	Espondilolistesis Degenerativa
IA	Inteligencia Artificial
KVC	K-Vecinos Cercanos
LTM	Logistic Model Trees (Árboles de Modelos Logísticos)
MSV	Máquina de Soporte del Vector
MRI	Resonancia Magnética
ReLU	Unidad Lineal Rectificada
RNA	Redes Neuronales Artificiales
RNRG	Red Neuronal de Regresión Generalizada
RNRP	Red Neuronal de Retro Propagación
RRP	Red de Región Propuesta
TC	Tomografía Computarizada

## GLOSARIO

**Algoritmo:** es un conjunto organizado y específico de instrucciones matemáticas y lógicas con el objetivo de poder solucionar problemas o realizar una tarea específica (Cumbal, 2022).

**Aprendizaje de transferencia profunda:** es un campo dentro del aprendizaje automático y la inteligencia artificial que utiliza redes neuronales ya entrenadas en tareas específicas con el objetivo de aumentar el desempeño en tareas distintas o relacionadas (Abdullah et al., 2018).

**Aprendizaje profundo:** es un campo dentro del machine learning (aprendizaje automático) que involucra redes neuronales artificiales que contienen diferentes capas para reconocer características de los datos (Rusk, 2016).

**Base de datos:** es un grupo de datos que están organizados y almacenados para posteriormente ser analizados, investigados, entre otros propósitos (Cumbal, 2022).

**Inteligencia artificial:** son máquinas o sistemas informáticos que se encargan de realizar actividades que requieren habilidades humanas como el aprendizaje, toma de decisiones o la solución de problemas (Pérez et al., 2018).

**Sobreajuste:** es cuando un modelo de aprendizaje automático se ajusta a los datos hasta que los aprende perfectamente, pero no lo puede realizar con datos que no haya visto anteriormente (Bautista-Hernandez et al., 2022).

**Subajuste:** ocurre cuando un modelo de aprendizaje automático no ha aprendido lo suficiente para capturar datos en el entrenamiento (Bautista-Hernandez et al., 2022).

**Redes neuronales convolucionales:** forman parte de las redes neuronales artificiales para procesar datos como imágenes (Li et al., 2022).

**Visión por computadora:** es una rama dentro de la informática y la inteligencia artificial cuyo fin es crear algoritmos que permiten a las máquinas entender y comprender el entorno por medio de videos e imágenes (Mahajan et al., 2022).

## I. INTRODUCCIÓN

Las deformidades de la columna vertebral como la escoliosis y la espondilolistesis son las principales causas de consulta traumatológica tanto en jóvenes como en adultos mayores. La escoliosis se comprende como una alteración tridimensional de la columna vertebral, provocando que en el plano coronal se exceda diez grados, esta suele ser acompañada de rotaciones vertebrales y desviación de la columna vertebral en el plano sagital (Barreras, 2011).

La columna vertebral se articula con la cabeza en la parte superior y con los dos huesos de la cadera en la parte inferior, que a su vez se conectan con las extremidades inferiores, formando el eje central del esqueleto del cuerpo. Las regiones cervicales, torácicas, lumbares, sacras y coccígeas componen la columna vertebral (Mahadevan, 2018). Según Bydon et al. (2019), una de las causas más frecuentes del dolor lumbar es la espondilolistesis, que se define como el desplazamiento de una vértebra sobre la vértebra adyacente en ausencia de una ruptura o defecto en el anillo vertebral. Se refiere ampliamente a la inestabilidad del segmento causada por la traslación de una vértebra sobre la otra.

Para el diagnóstico y validación de las deformidades anteriormente descritas y que se explorarán a lo largo de este documento, se propone la implementación del aprendizaje de transferencia profunda como complemento en la valoración realizada por médicos especialistas en el área. El campo del aprendizaje profundo ha generado notables avances en diversas áreas de la visión por computadora, abordando desafíos como la detección de objetos, el seguimiento de movimiento, la identificación de acciones y la segmentación semántica. En este caso, se enfocará la aplicación de las redes neuronales convoluciones (CNN) a tareas de clasificación, tomando como modelos pre-entrenados los siguientes: MobileNetV3-Small, MobileNetV3-Large, EfficientNetV2B0, EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2.

Este proyecto de investigación propone mejorar el desempeño de un algoritmo de clasificación de radiografías de la columna vertebral, por medio de modificaciones y entrenamiento con una base de datos de imágenes radiográficas previamente definida.

Además, se colaborará con la Sociedad de Neurocirujanos de Honduras y tres hospitales de la zona norte de Honduras para la creación de una base de datos de imágenes radiográficas de la columna vertebral para la validación del algoritmo del estado del arte.

En el Capítulo II de este documento, se presenta: El Planteamiento del Problema, el cual estará fundamentado en base a la situación actual de Honduras. Por lo tanto, se continuará definiendo el Capítulo III: Estado del Arte. Por consiguiente, se presenta el Capítulo IV: Metodología, donde se establecen los métodos desarrollados que permitieron la obtención de resultados que fueron evaluados y presentados en el Capítulo V: Resultados y Análisis.

Por último, se presenta el Capítulo VI: Conclusiones, donde se evidencia la medición de los resultados obtenidos destacando la realidad de la investigación desarrollada. Con el Capítulo VII: Recomendaciones donde se establecieron procedimientos para mejorar la situación actual ante el problema de investigación. Por último, en los Capítulos VIII y IX, se planteó la aplicabilidad e implementación de dicha investigación y expondrán futuros trabajos de investigación.

## **II. PLANTEAMIENTO DEL PROBLEMA**

Dentro de este capítulo, se presentan los antecedentes a nivel internacional, dado que, en Honduras, no se han validado estudios relacionados al área de entrenamiento de algoritmos para la detección de problemas de la columna vertebral ni se disponen de estadísticas sobre la frecuencia de casos de escoliosis y espondilolistesis. Es por ello, la importancia de definir el problema, justificarlo y establecer objetivos y preguntas de investigación para que, a partir de estos, se pueda definir el alcance de dicha investigación.

### **2.1 PRECEDENTES DEL PROBLEMA**

Según Perrot-González et al. (2013), la escoliosis idiopática es una deformidad tridimensional de la columna vertebral que tiene una prevalencia que oscila entre el 1.5 y el 3% de la población mundial. Sin embargo, estos son índices que con el pasar de los años pueden ir aumentando debido a los cambios en los estilos de vida de la población. La investigación realizada por Vargas & Meléndez (2018) para la Revista Médica de Costa Rica y Centroamérica, expone un estudio para conocer la prevalencia de escoliosis en pacientes con parálisis cerebral. Como resultado se obtuvo que, de 74 sujetos estudiados, 45 contaban con escoliosis indicando que un 60.81% de los pacientes padecían con esta deformidad en su columna vertebral.

Además, Ortega et al. (2014) realizaron un análisis de la prevalencia de la escoliosis en una población escolar mexicana. Los resultados de este estudio demostraron que de 295 sujetos estudiados hubo un total de 14.2% de los pacientes que presentaban escoliosis, siendo este porcentaje la cantidad de 42 sujetos. Muñoz (2011), por otro lado, determinó en una investigación realizada en Ecuador que las personas que padecen con mayor frecuencia esta deformidad son los adolescentes de 10 a 16 años. El porcentaje de la población total que padece de algún tipo de escoliosis es del 2.3%.

Según Vázquez-Aguilar et al. (2016), la espondilolistesis es una deformidad generada por un movimiento excesivo de una vértebra sobre otra; es la afección más frecuente y se presenta a un nivel de L4-L5. Debido a la ubicación de esta deformidad, ha sido indicada como una de las principales patologías causantes del dolor de espalda baja. Según la investigación realizada por Martínez & Pérez (2018) en la ciudad de Puebla en México, el

dolor de espalda baja es una de las principales causas de incapacidad en dicho país y que esta va relacionada con la espondilolistesis degenerativa, debido a que se encontró que en el 67.4 % de los casos el dolor de espalda baja es producido por dicha deformidad. En los resultados de la investigación se obtuvo que la prevalencia fue de 7.5% en hombres y 16.7-28% en mujeres.

El diagnóstico de estas deformidades muchas veces se realiza de manera subjetiva y tardía, esto debido al poco desarrollo de tecnologías y pocas investigaciones en este ámbito, por lo que se ve necesario el desarrollo de estudios relacionados a estas deformidades de la columna vertebral que afectan a la población hondureña.

Actualmente, en Honduras no se encuentran antecedentes del desarrollo de algoritmos para clasificar desviaciones vertebrales por medio de imágenes radiográficas. Sin embargo, en la investigación de Ojeda (2022) se utilizó una red neuronal convolucional (CNN) para la clasificación de escoliosis y pacientes sanos a partir de imágenes radiográficas de la columna vertebral para que el algoritmo sirva de apoyo al personal de salud pertinente. Se deben de contar con diferentes parámetros; como el lote siendo este, las imágenes que se ingresan. La época; siendo esta completada cuando el entrenamiento pasa por cada etapa del aprendizaje.

Como metodología en la investigación de Ojeda (2022) , se parte de la extracción de imágenes de diferentes bases de datos, las imágenes se distribuyen para entrenamiento y para prueba, se diseñó y construyó la red y por último se entrenó y validó dicha red. Como resultados, se presentaron diferentes dificultades al momento de realizar la clasificación de las diferentes clases de escoliosis, no obstante, tuvo un porcentaje de 79.2% de clasificación con pacientes con escoliosis tipo "C" y "S". Por otro lado, tuvo un porcentaje de clasificación de 94% cuando se utilizaron radiografías de pacientes sanos.

Del mismo modo, Romero Rodríguez (2019) realizó una investigación para reconocer alteraciones posturales a través de imágenes radiográficas de la columna vertebral. Su investigación se dividió en cinco fases: adquisición de imágenes radiográficas, procesamiento de dichas imágenes, entrenamiento de la red, segmentación de las imágenes y la medición automática del ángulo de desviación. Dentro de la fase de entrenamiento, se

utilizó el modelo de Máscara Red Convolutiva (CNN) la cual contiene la capa de convolución, reducción y clasificadora.

Para detectar las regiones que poseen objetos, se utilizó la aplicación Region Proposal Network, que es una red neuronal ligera que permite escanear cada una de las imágenes. Los resultados de esta investigación mostraron que el sistema poseía una correlación de Pearson de 0.865. Esta correlación expone la relación estadística que contienen dos variables que son continuas. Además, esto implica que las mediciones son directamente proporcionales, indicando que el sistema es confiable por la información brindada y al confirmar la hipótesis de la investigación la cuál era "El desarrollo de un sistema para el procesamiento de imágenes médicas contribuye a la detección temprana de alteraciones posturales".

En una investigación presentada por Pérez et al. (2018), se utilizó algoritmos como LMT (Logistic Model Trees), redes bayesianas, naive bayes, J48 y naive bayes simples para poder analizar cuál era el mejor algoritmo de decisión y clasificador. Los resultados mostraron que el algoritmo LMT tuvo un porcentaje de 85.48% con un error de 0.2168, redes bayesianas tuvo un porcentaje de 80% y un error de 0.249, Naive Bayes obtuvo un error de 0.2, el J48 obtuvo una clasificación de 253 instancias y Naive Bayes Simple obtuvo 241 instancias. Como conclusión, se demostró estadísticamente que el mejor algoritmo de decisión fue el LMT y el mejor clasificador fue el algoritmo Naive Bayes. Por ende, la precisión del algoritmo Naive Bayes como mejor clasificador es de 92.37%, mientras que la exactitud del algoritmo LMT como mejor algoritmo de decisión es de 68.68%.

Por último, no existe una base de datos de imágenes radiográficas sobre desviaciones de la columna vertebral en Honduras, por lo que será necesario utilizar una serie de bases de datos públicas para poder realizar la investigación correctamente. Además, para beneficios de futuras líneas de investigación sobre este tema, se entregará una base de datos con información de pacientes hondureños, en colaboración con la Sociedad de Neurocirujanos de Honduras y tres hospitales de la zona norte del país.

## **2.2 DEFINICIÓN DEL PROBLEMA**

En Honduras, actualmente no se cuenta con herramientas tecnológicas basadas en inteligencia artificial como lo son los algoritmos de clasificación para el apoyo en el proceso de diagnóstico de patologías como la escoliosis y espondilolistesis. Los algoritmos de clasificación se encargan de extraer características de las imágenes que son objeto de estudio y en base a los resultados obtenidos, se pueden organizar en diferentes clases permitiendo la optimización en el proceso de detección de estas deformidades de la columna vertebral. La implementación de un algoritmo involucra el cumplimiento de diversos parámetros como ser la exactitud que debe ser alta en esta aplicación. Además, esta es una línea de investigación poco explorada, evitando que se cuente con bases de datos propias de imágenes médicas pertenecientes a pacientes hondureños con estas desviaciones, para el desarrollo de fases de validación de un algoritmo de clasificación de imágenes radiográficas de la columna vertebral.

### **2.3 JUSTIFICACIÓN**

La implementación de un algoritmo de clasificación de radiografías de la columna vertebral es de gran valor para el diagnóstico de deformidades como son la escoliosis y la espondilolistesis. En el caso de la escoliosis el diagnóstico es reforzado por medio de radiografías de la columna vertebral y la toma de datos biomecánicos como ser el ángulo de Cobb, cuyo valor indica el grado de escoliosis que está presente en el paciente. Seguidamente, el diagnóstico de la espondilolistesis habitualmente se realiza por medio de la evaluación de una radiografía lumbar que suele verse acompañada de imágenes por resonancia magnética, por medio de estas imágenes se obtienen los valores de rotación y traslación sagitales, que son claves para brindar un diagnóstico acertado.

Por lo tanto, es de interés que este tipo de algoritmo sea propiamente entrenado y evaluado en relación con su exactitud. La importancia de la exactitud en esta herramienta se ve reflejada en los resultados que pueden ser obtenidos y que son de utilidad para la detección temprana de las deformidades mencionadas anteriormente. La optimización de este algoritmo permitirá en un futuro que sea un instrumento innovador en el campo de la salud, donde se beneficiará potencialmente a la población afectada por estas desviaciones de la columna vertebral, siendo una herramienta de asistencia y validación diagnóstica para el neurocirujano.

El material científico relacionado a deformidades como la escoliosis y la espondilolistesis en Honduras, se basa únicamente en la revisión de casos. Por consiguiente, contribuir con la Sociedad de Neurocirujanos de Honduras y tres de los hospitales de la zona norte del país, para la creación de una base de datos de imágenes radiográficas de pacientes hondureños que padecen de estas desviaciones de la columna vertebral, permitirá validar el algoritmo de clasificación para evaluar su exactitud y de esta manera colaborar con material científico para futuras líneas de investigación en esta rama.

## **2.4 PREGUNTAS DE INVESTIGACIÓN**

### 2.4.1 PREGUNTA GENERAL

1. ¿Cómo se pueden aumentar las métricas de desempeño de un algoritmo de clasificación de radiografías de escoliosis y espondilolistesis para su aplicación en imágenes radiográficas de la columna vertebral de pacientes hondureños?

### 2.4.2 PREGUNTAS ESPECÍFICAS

1. ¿Qué parámetros se deben de modificar del modelo existente basados en la literatura para mejorar las métricas de desempeño del algoritmo?
2. ¿Son funcionales los modelos del estado del arte en imágenes de rayos X de pacientes hondureños?
3. ¿Cómo se puede crear una base de datos con las imágenes recolectadas?

## **2.5 OBJETIVOS**

### 2.5.1 OBJETIVO GENERAL

1. Aumentar las métricas de desempeño de un algoritmo de clasificación de radiografías de escoliosis y espondilolistesis.

### 2.5.2 OBJETIVOS ESPECÍFICOS

1. Modificar parámetros de los modelos existentes basados en la literatura para intentar mejorar las métricas de desempeño del algoritmo.
2. Utilizar imágenes de rayos X de pacientes hondureños proporcionadas por la Sociedad de Neurocirujanos de Honduras, y tres hospitales de la zona nor-occidental del país para evaluar la aplicabilidad del algoritmo en imágenes utilizadas en el país.
3. Crear una base de datos con las imágenes recolectadas.

### **III. ESTADO DEL ARTE**

El siguiente capítulo presenta el Estado del Arte, desde un abordaje de macroentorno en donde se explora la situación actual del problema de investigación en relación con investigaciones desarrolladas a nivel internacional, posteriormente se evalúa el microentorno, en donde se realiza una revisión de literatura existente en Latinoamérica y se destaca la importancia del desarrollo de este tipo de investigaciones a nivel nacional debido a la poca información existente relacionada al tema.

#### **3.1 ANÁLISIS DE LA SITUACIÓN ACTUAL**

Las deformidades de la columna vertebral como son la escoliosis y la espondilolistesis pertenecen a las principales causas de consulta en la población general. El proceso de diagnóstico actual se puede resumir en la inspección visual del paciente, por medio del reconocimiento de patrones por parte del especialista. Para el caso de ambas deformidades, la adquisición de los datos biomecánicos como los ángulos y traslaciones de interés, son obtenidos de manera subjetiva, basándose principalmente en la experiencia del especialista, indicando que se puedan generar variaciones en las mediciones realizadas generando así posibles errores en el diagnóstico.

Debido a esta circunstancia se hace imprescindible el desarrollo de herramientas que sean de soporte para el diagnóstico de estas deformidades. Los clasificadores de imágenes médicas vienen siendo uno de los instrumentos propuestos para el apoyo en el diagnóstico de diferentes patologías, esta herramienta utiliza el aprendizaje profundo para la detección de patrones y brindar así una clasificación de las imágenes en diferentes clases dependiendo de las características extraídas.

##### **3.1.1 MACROENTORNO**

En el análisis del macroentorno se evalúa la literatura internacional desde el punto de vista del valor que poseen los clasificadores de aprendizaje automático para el diagnóstico de deformidades de la columna vertebral. Este análisis surge a partir de la revisión de diversas metodologías empleadas alrededor del mundo fuera de Latinoamérica, para el desarrollo de algoritmos basados en aprendizaje automático y profundo que consigan

dividir en diferentes clases las imágenes radiográficas de la columna vertebral de modo que se puedan clasificar según las características de cada deformidad estudiada.

La investigación realizada por Ansari et al. (2013), demuestra la utilización de dos clasificadores de aprendizaje automático para el diagnóstico de alteraciones de la columna vertebral que involucra el uso de Redes Neuronales Artificiales (RNA) y la Máquina de Soporte del Vector (MSV). Las clases de clasificación en esta investigación son; paciente sin escoliosis, paciente con espondilolistesis y paciente con hernia de disco.

La metodología del estudio es dividida en tres fases, siendo la primera la fase de Preprocesamiento, la segunda, la fase del Diseño del Clasificador y la tercera, la fase de Post Procesamiento. La fase de Preprocesamiento consistió en la recolección de imágenes de resonancia magnética de pacientes con espondilolistesis, pacientes que sufren de hernia de disco y pacientes con columnas vertebrales sin escoliosis. Seguidamente los investigadores destacaron que se debió analizar y limpiar los datos de las imágenes, de modo que se pudiera reducir el ruido presente en los mismos. Luego en el estudio se procedió a dividir la base de datos en dos conjuntos, el conjunto de entrenamiento y el conjunto de pruebas. Los investigadores lo realizaron por medio de dos métodos, siendo el primero una división con una proporción de muestras del 50% y el segundo método empleado se basó en una validación cruzada de diez pliegues.

La fase de Diseño del Clasificador consistió en el desarrollo de dos clasificadores mediante el uso de dos diferentes RNA las cuales son; la Red Neuronal de Retro Propagación (RNRP) y la Red Neuronal de Regresión Generalizada (RNRG), y el empleo de un MSV. Ambos clasificadores realizados fueron envueltos en dos fases de entrenamiento con diferentes bases de datos. La fase de Post Procesamiento en la investigación consistió en la transformación de los resultados de la fase anterior a datos que sean entendibles, los resultados de esta fase se basaron en poder designar si la imagen era perteneciente a un paciente con la columna vertebral normal o si poseía una deformidad, y si poseía una alteración si esta era espondilolistesis o hernia de disco.

Según la investigación desarrollada por Ansari et al. (2013) cada una de las muestras con las que se trabajó, contenía seis atributos, los cuales fueron identificados como

incidencia e inclinación pélvica, ángulo de lordosis lumbar, pendiente sacra, radio pélvico y grado de espondilolistesis. Todos estos atributos fueron utilizados por los investigadores para obtener la clasificación en las clases correspondientes.

Por último, en el estudio se decidió utilizar un MSV, como un tercer clasificador diferente a las RNA empleadas. Para este clasificador también se realizaron los dos abordajes para la separación de la base de datos en los conjuntos de entrenamiento y pruebas. Los resultados de esta investigación se basaron en presentar el porcentaje de exactitud de los tres clasificadores evaluados utilizando los dos métodos descritos para la división de la base de datos. Los resultados demuestran que el clasificador basado en RNRG obtuvo un mejor rendimiento que el clasificador basado en RNRP y MSV, con un porcentaje de exactitud de 92.02%, para cuando se utilizó el método de división con una proporción de muestras del 50% (Tabla 1).

**Tabla 1- Resultados de clasificadores con el método de división con una proporción de muestras del 50%.**

<b>Conjunto de Datos</b>	<b>Número de Muestras</b>	<b>Red Neuronal de Retro Propagación</b>	<b>Red Neuronal de Regresión Generalizada</b>	<b>Máquina de Soporte del Vector</b>
Conjunto de Entrenamiento	159	86.79%	100%	100%
Conjunto de Pruebas	151	86.76%	92.05%	86.87%

Fuente: (Ansari et al., 2013)

Por otro lado, en el caso del método de validación cruzada de diez pliegues, los resultados obtenidos fueron que el clasificador basado en RNRP obtuvo mayor porcentaje de exactitud en comparación al clasificador basado en RNRG y la MSV con un porcentaje de exactitud de 93.87% (Tabla 2).

**Tabla 2- Resultados de método de validación cruzada de diez pliegues.**

<b>Número de Pliegues</b>	<b>Número de Muestras</b>	<b>Red Neuronal de Retro Propagación</b>	<b>Red Neuronal de Regresión Generalizada</b>	<b>Máquina de Soporte del Vector</b>
1	1-31	90.32%	80.65%	86.33%
2	32-62	90.32%	80.65%	81.49%
3	63-93	87.10%	77.42%	86.33%
4	94-124	90.32%	74.19%	82.34%
5	125-155	96.77%	93.55%	91.94%
6	156-186	93.55%	87.10%	87.10%
7	187-217	100%	83.87%	89.43%
8	218-248	100%	96.77%	88.79%
9	249-270	96.77%	93.55%	92.78%
10	271-310	93.55%	80.65%	86.33%
<b>Total</b>	<b>Promedio</b>	<b>93.87%</b>	<b>84.84%</b>	<b>87.29%</b>

Fuente: (Ansari et al., 2013)

Prosiguiendo con la revisión exhaustiva de la literatura, el estudio realizado por Abdullah et al. (2018) en Malasia, tiene como objetivo principal identificar por medio de datos extraídos de pacientes si estos poseen desviaciones en la columna vertebral o no. Dentro de los datos que fueron recolectados por los investigadores se destacan doce características que fueron factores claves para el desarrollo de la clasificación de los datos recopilados. Las características fueron las siguientes; incidencia e inclinación pélvica, ángulo de lordosis lumbar, pendiente sacra, radio pélvico, inclinación directa, pendiente torácica, pendiente pélvica, inclinación cervical, grado de espondilolistesis, ángulo sacro y escoliosis.

Para el desarrollo de predicciones de anomalías de la columna vertebral Abdullah et al. (2018), tomaron en cuenta tres diferentes modelos de aprendizaje automático, el primer modelo utilizado es el llamado Análisis de Componente Principal (ACP), también se utilizó el modelo denominado como Bosque Aleatorio (BA), y por último utilizaron el modelo comprendido como K-Vecinos Cercanos (KVC). La metodología empleada en este estudio consistió en varios pasos, empezando por la extracción de datos, seguidamente se continuó con una limpieza de la información, se prosiguió con una extracción de las características,

finalmente se concluyó la investigación con las clasificaciones desarrolladas por los modelos de aprendizaje automático evaluados.

La fase de extracción de datos consistió en obtener datos pertenecientes a la columna vertebral de varios pacientes en una base de datos del sitio web de Kaggle. El conjunto de datos estaba compuesto por trescientas diez imágenes que se clasificarían en dos clases. La primera clase pertenece a los pacientes normales que está compuesta por un total de cien imágenes recolectadas, por otro lado, la segunda clase está conformada por un total de doscientos diez pacientes que poseen una anormalidad en la columna vertebral. La fase de limpieza de información se realizó por medio del remplazo de los atributos que fueron descritos con valores numéricos por el nombre correspondiente a cada característica.

La fase de extracción de características se realizó por medio del uso del modelo ACP, el cual según Abdullah et al. (2018) emplea un método estadístico para reducir el número de variables en un conjunto de datos. El primer componente principal en el estudio se denotó como el que posee mayor varianza entre datos, mientras que el segundo componente principal se comprendió como no relacionado al primer componente, sin embargo, también contaba con la mayor varianza de datos. En el momento del desarrollo del clasificador, se utilizó el modelo BA, como aprendizaje automático supervisado. De manera general los investigadores describen que se presentaron dos etapas para trabajar con el modelo BA, siendo la primera la creación del bosque aleatorio y luego el desarrollo de la predicción del modelo implementado en la primera etapa.

Además del empleo del clasificador BA, Abdullah et al. (2018) utilizaron el algoritmo KVC, para la clasificación de la información en dos clases denominadas como; paciente normal y paciente con anormalidades. El algoritmo KVC, se basa en la selección de un valor  $k$ , que indica el valor de vecinos cercanos, este valor en la investigación determina el grado de eficacia del modelo al momento del desarrollo de la clasificación. Lo que indican los investigadores, es que al asignar un valor alto de  $k$  suele otorgar una ventaja debido a que reduce la varianza provocada por la información ruidosa.

Para evaluar ambos modelos, en el estudio se aplicaron las siguientes métricas; exactitud, precisión, sensibilidad y especificidad. El desarrollo del entrenamiento de los

algoritmos se logró por medio de la aplicación de dos divisiones del conjunto de datos, primeramente, se definió un 80% del conjunto de datos para el entrenamiento y un 20% para las pruebas, seguidamente se realizó una segunda división con un 70% de datos para entrenamiento y un 30% para el desarrollo de pruebas.

Los resultados de las métricas aplicadas demuestran que para el modelo BA, se obtuvo un valor de 79.03% de exactitud al momento de separar la base de datos en un 20% para el desarrollo de pruebas. Por otro lado, al dividir la base de datos en un conjunto de 30% para pruebas se alcanzó mayor exactitud siendo de un 79.57% (Tabla 3).

**Tabla 3- Resultados de exactitud, sensibilidad, especificidad, y precisión, después de usar 20% y 30% de los datos como datos de prueba en el clasificador BA.**

<b>Datos de Prueba</b>	<b>Exactitud (%)</b>	<b>Sensibilidad (%)</b>	<b>Especificidad (%)</b>	<b>Precisión (%)</b>
20%	79.03	84.62	72.73	82.50
30%	79.57	87.50	78.13	80.33

Fuente: (Abdullah et al., 2018)

Por otro lado, al evaluar el algoritmo KVC, se implementaron dos tipos de modelos siendo estos los algoritmos KVC; triangular ponderado y rectangular ponderado para la realización de las predicciones. Se probaron un total de diez valores k, para cada una de las divisiones de la base de datos implementada por los investigadores, obteniendo que al separar la base de datos en un 20% para el desarrollo de pruebas se obtuvo el valor máximo de exactitud utilizando un valor de  $k=7$ , con un porcentaje de 85.32%. En el caso de la división de 30% para el desarrollo de pruebas se obtuvo un porcentaje máximo de exactitud de 83.67% con un valor de  $k=8$ .

El trabajo realizado por Imran et al. (2020), muestra la implementación de un análisis automático de escoliosis a partir de imágenes radiográficas de la columna vertebral. La exploración realizada hace bastante énfasis en que los procesos actuales relacionados a la segmentación de imágenes y la medición del grado de escoliosis se realiza de manera manual, suponiendo ciertas dificultades para aportar un diagnóstico óptimo de la desviación vertebral en cuestión. La contribución realizada por estos investigadores es el desarrollo de un sistema automatizado, es decir, que no requiere de intervención manual ni fases de

preprocesamiento para otorgar una segmentación de la columna vertebral con un etiquetado de cada vértebra, además de aproximar el ángulo de Cobb y realizar una clasificación del grado de escoliosis que presenta el paciente.

Para el alcance de los objetivos propuestos por Imran et al. (2020), se plantearon un total de cinco etapas; segmentación vertebral a través de una U-net progresiva, medición del ángulo de Cobb, clasificación de escoliosis, experimentación y resultados. Para la primera etapa, los investigadores modificaron ciertos parámetros del modelo U-net, esto por medio de la adición de un codificador y un decodificador, en cada una de las capas del codificador se empleó dos convoluciones de una matriz de 3x3 que además seguidamente se aplica una normalización a las capas. Posteriormente se realiza una función de activación denominada como ReLU, y un agrupamiento máximo definido por una matriz 2x2. Por último, se aplica una técnica de regularización en cada etapa del codificador y el decodificador. A partir de este paso, los investigadores mencionan que en el modelo implementado se generan salidas laterales, de modo que se pueda mejorar el rendimiento de la segmentación de la columna vertebral.

La segunda etapa denominada como la medición del ángulo de Cobb, se realizó por medio de la obtención de la máscara realizada en la fase anterior. El primer paso consistió en obtener los contornos a partir de la máscara binaria generada, luego los contornos son ordenados desde arriba hasta abajo, por último, para cada uno de los pares de contornos separados por al menos un contorno, el par que posee el valor máximo de diferencia angular entre la pendiente de la línea superior asociada con el contorno superior y la pendiente de la línea inferior asociada con el contorno inferior determina el ángulo de Cobb.

La etapa comprendida como clasificación de escoliosis, se realizó a partir de la medida del ángulo de Cobb obtenido. Debido a esta medida, Imran et al. (2020) determinaron cuatro clasificaciones en relación a la severidad de la escoliosis; severa, moderada, leve y normal. A lo largo de la metodología empleada, se hace hincapié que los datos para la etapa de experimentación fueron recolectados de la Universidad de Hong Kong, se recogió un total de cien imágenes radiográficas de pacientes con indicios de escoliosis. La división del

conjunto de datos fue por medio de la asignación de un 80% de los datos para el entrenamiento, un 15% para el desarrollo de pruebas y 5% para validación.

Para la fase de experimentación para el uso del modelo U-net seleccionado, se trabajó con cuatro versiones de este, siendo la primera un modelo U-net con una elección de entropía cruzada binaria que los investigadores denominaron como UX. Otra de las versiones ejecutadas es el modelo U-net con una función de pérdida denominada como Dice, a esta versión se le denominó UD. Además, se realizaron experimentos con las versiones progresivas de los modelos descritos anteriormente PUX (U-net progresiva con entropía cruzada) y PUD (U-net progresiva con pérdida de Dice). Para elaborar esta fase del estudio se decidió colocar como ritmo inicial de aprendizaje de 0.01, el cual disminuiría a partir de cada veinte épocas alcanzadas. Los resultados recolectados en este abordaje se basaron en evaluar las métricas obtenidas a partir del análisis de la segmentación resultante.

Los resultados presentados por Imran et al. (2020), se basan en porcentajes obtenidos de la similitud Dice (DS), índice de similitud estructural (ISS), distancia promedio de Hausdorff (HD) y el puntaje F1 (F1). Los valores más altos de DS, ISS y el F1 indican mejor segmentación entre las referencias obtenidas y las predicciones. Por otro lado, valores bajos de HD representan mejor predicción en la segmentación. De las cuatro versiones del modelo U-net empleadas, la que obtuvo mejor resultados fue la PUX (U-net progresiva con entropía cruzada) con un DS de 99.3%, un ISS de 97% y un puntaje F1 de 92.2%. La versión PUD (U-net progresiva con pérdida de Dice), obtuvo el valor menor de HD siendo de 4.597 además obtuvo el mismo porcentaje de DS que el modelo PUX de 99.3% (Tabla 4).

**Tabla 4- Comparación de rendimiento de modelos de segmentación de columna vertebral.**

<b>Modelo</b>	<b>DS</b>	<b>ISS</b>	<b>HD</b>	<b>F1</b>
UD	0.970	0.961	5.246	0.896
UX	0.956	0.955	6.767	0.868
PUD	0.993	0.966	4.597	0.919
PUX	0.993	0.970	4.677	0.922

Fuente: (Imran et al, 2020)

La investigación desarrollada por Fraiwan et al. (2022) en Jordania, buscó el desarrollo de un sistema de inteligencia artificial para el diagnóstico de la escoliosis y la espondilolistesis, el objetivo principal del estudio es el de evaluar catorce diferentes modelos de aprendizaje profundo pre-entrenados, con radiografías de la columna vertebral de pacientes con las deformidades mencionadas anteriormente. Los modelos utilizados en esta investigación son específicamente las Redes Neuronales Convolucionales (RNC), además, en el estudio se empleó específicamente el aprendizaje de transferencia el cual se ve implementado en los modelos que evalúan en la investigación.

Dentro de la metodología empleada en este abordaje, se realizó un preprocesamiento para evitar que existiera un sobreajuste de los modelos a detalles específicos de las imágenes. Es importante destacar que, en esta investigación, para el entrenamiento de los modelos se destinó una configuración de un máximo de seis épocas y un rango inicial de aprendizaje de 0.001. Posteriormente en el estudio se empleó un optimizador de descenso de gradiente estocástico para el entrenamiento. Luego se definió un método de retención con una división del 70% para entrenamiento y un 30% para pruebas, estos porcentajes representan la cantidad de imágenes que se utilizaron en estas fases del estudio en relación con el total de imágenes obtenidas en la base de datos.

Para los resultados de la exploración realizada, se desarrollaron un total de cuarenta pruebas a cada modelo obteniendo así una exactitud mínima, máxima, promedio y desviación estándar, además se reportan métricas de rendimiento, que incluyen la precisión, la especificidad, sensibilidad, y el puntaje F1 para cada modelo. Los catorce modelos evaluados en el estudio fueron: SqueezeNet, GoogLeNet, Inception-v3, DenseNet-201, MobileNets, ResNet-101, ResNet-50, ResNet-18, Xception Model, Inception-ResNet-v2, ShuffleNet, NASNet-Mobile, DarkNet-53 y EfficientNet-b0. Los resultados obtenidos remarcan que el modelo llamado DenseNet-201 obtuvo el valor más alto de exactitud media, exactitud máxima y exactitud mínima siendo 96.34%, 99.01% y 94.06% respectivamente.

Luego se observa que el modelo que obtuvo menor exactitud es el de EfficientNet-b0, con el valor de exactitud media más bajo del estudio siendo 87.92%, además el modelo

llamado NASNet-Mobile, obtuvo el menor valor de exactitud mínima en el desarrollo de las pruebas, siendo de 78.22% (Tabla 5).

**Tabla 5- Exactitud de clasificador de radiografías en tres clases; normal, escoliosis y espondilolistesis, para cada modelo de aprendizaje profundo.**

<b>Modelo</b>	<b>Exactitud Media</b>	<b>Exactitud Máxima</b>	<b>Exactitud Mínima</b>	<b>Desviación Estándar</b>
SqueezeNet	91.29%	95.05%	87.13%	2.94%
GoogLeNet	93.76%	96.04%	91.09%	1.40%
Inception-v3	92.97%	95.05%	89.11%	1.83%
DenseNet-201	96.34%	99.01%	94.06%	1.48%
MobileNet-v2	91.39%	95.05%	88.12%	1.75%
ResNet-101	93.27%	95.05%	86.14%	2.71%
ResNet-50	94.36%	96.04%	91.09%	1.98%
ResNet-18	94.26%	95.05%	92.08%	1.02%
Xception	88.22 %	92.08%	85.15%	2.58%
Inception-ResNet-v2	90.30%	94.06%	83.17%	3.05%
ShuffleNet	92.38%	96.04%	89.11%	2.38%
NASNet-Mobile	90.30%	95.05%	78.22%	4.80%
DarkNet-53	91.58%	95.05%	86.14%	2.85%
EfficientNet-b0	87.92%	91.09%	83.17%	2.18%

Fuente: (Fraiwan et al., 2022)

Seguidamente para cada uno de los modelos evaluados se presentaron resultados de las métricas mencionadas anteriormente, gracias a esto se logró concluir que el modelo DenseNet-201, fue el que alcanzó el porcentaje más alto en cada una de las métricas como son, el puntaje F1, la precisión, la sensibilidad y la especificidad, con porcentajes de 95.97%, 97.61%, 94.62% y 97.89% respectivamente. El modelo que tuvo el menor puntaje F1 fue EfficientNet-b0 con 86.41%, el menor porcentaje de precisión fue NASNet-Mobile con un 90.99%, el menor porcentaje de sensibilidad lo presentó el modelo EfficientNet-b0 con un 82.62% y el menor porcentaje de especificidad lo obtuvo el modelo NASNet-Mobile con un 91.00% (Tabla 6).

**Tabla 6- El puntaje F1 promedio general, precisión y sensibilidad, para los catorce modelos de aprendizaje profundo, realizando clasificación de tres clases.**

<b>Modelo</b>	<b>Puntaje F1</b>	<b>Precisión</b>	<b>Sensibilidad</b>	<b>Especificidad</b>
SqueezeNet	89.98%	94.10%	88.00%	94.54%
GoogLeNet	93.24%	95.52%	91.55%	95.88%
Inception-v3	92.32%	94.66%	90.93%	94.97%
DenseNet-201	95.97%	97.61%	94.62%	97.89%
MobileNet-v2	90.35%	93.74%	88.13%	94.45%
ResNet-101	92.55%	96.15%	90.16%	96.38%
ResNet-50	93.84%	96.74%	91.79%	96.91%
ResNet-18	93.82%	96.65%	91.73%	96.80%
Xception	86.71%	93.08%	83.47%	93.32%
Inception-ResNet-v2	89.34%	92.99%	87.36%	93.29%
ShuffleNet	91.74%	94.48%	90.28%	94.55%
NASNet-Mobile	89.77%	90.99%	89.62%	91.00%
DarkNet-53	90.62%	94.77%	88.23%	95.01%
EfficientNet-b0	86.41%	92.98%	82.62%	93.47%

Fuente: (Fraivan et al., 2022)

### 3.1.2 MICROENTORNO

En el análisis del microentorno se evalúa en un inicio la literatura desarrollada por investigadores en Latinoamérica, realizando una exploración sobre cómo se encuentra el problema de investigación en países que presentan similares circunstancias a las de Honduras. Asimismo, se evalúa la situación actual de salud nacional en referencia a las deformidades de la columna vertebral que son objeto de este estudio. Claramente, tanto la escoliosis como la espondilolistesis forman parte de un grupo de deformidades que afectan a un gran número de personas en toda Latinoamérica. Debido a las limitantes de la región en relación con las prioridades de investigación, acceso a tecnología e información, escasez de financiamiento y dificultades en recopilación de datos, es que no se poseen estadísticas generales del área en cuanto a los datos de prevalencia de ambas deformidades.

Sin embargo, en los últimos años, son varios los investigadores que en busca de la obtención de estadísticas de estas deformidades desarrollan estudios observacionales y transversales. Un ejemplo de este tipo de exploración fue desarrollado por Vázquez-Lazarte et al. (2020) en Perú, debido a la falta de estudios estadísticos sobre la escoliosis, diseñaron un estudio observacional donde tomaron una población de diferentes colegios de la ciudad de Lima, la muestra final fue de 191 participantes, donde el 62.30% eran varones y el 37.70% eran mujeres con un promedio de edad de catorce años. Los resultados presentaron que un 55.50% de la muestra presentó un diagnóstico de columna vertebral normal, un 17.28% obtuvo un diagnóstico dudoso y un 27.23% obtuvieron un diagnóstico positivo a escoliosis idiopática.

Otra investigación desarrollada por Ortega et al. (2014) en México, se encarga de analizar la prevalencia de escoliosis en una localidad de la Ciudad del Carmen, tomando como población a menores de edad de entre nueve a doce años, con el fin de proporcionar datos de incidencia de la deformidad en los escolares mexicanos. El abordaje desarrollado tomó una muestra total de 295 estudiantes, cuya edad promediaba a los diez y once años. El estudio no solo brindó datos sobre la escoliosis sino también de los factores asociados a la misma, los resultados arrojaron que un 14.2% obtuvo un diagnóstico de escoliosis positivo, un 41.7% presentó una postura corporal incorrecta, 53.5% presentaron obesidad y el 63.7% no presentaba todavía el desarrollo madurativo.

Según Armenta et al. (2018), se ha visto un incremento grotesco de pacientes con deformidades de la columna vertebral, en la investigación desarrollada se hace énfasis en que existe poco material científico en referencia a datos de prevalencia de patologías ortopédicas de la columna vertebral en México. Por lo tanto, se realizó un estudio observacional y transversal utilizando una base de datos de un hospital mexicano, los datos analizados se componen de 7,771 casos donde el 50.4% es del género masculino con una edad promedio de 53.51 años. Los resultados obtenidos muestran que la patología con mayor incidencia fue la presencia de un conducto lumbar estrecho representando un 25.85%, luego se obtuvo que la hernia discal lumbar poseyó una incidencia de 23.12% y la

espondilolistesis fue diagnosticada en un 22.63% de la muestra estudiada representando un total de 1,758 pacientes.

Tomando en cuenta que, en Honduras, el material científico tanto de la escoliosis como la espondilolistesis se basa únicamente en la revisión de casos y no tanto en datos sobre incidencia de estas, se debe revisar el perfil de salud que existe a nivel nacional, considerando que estas deformidades afectan a diversos sectores de la población tanto a jóvenes como a adultos mayores. Por consiguiente, es de vital importancia hacer un repaso de la situación actual de salud en Honduras. Para el año 2021, Honduras alcanzó una población 10,278,346 habitantes, dentro de la cual un 5.4% representaba a la población de adultos mayores de 65 años, recordando que el perfil epidemiológico de la espondilolistesis registra que se presenta en adultos mayores a 50 años (OPS, 2022).

Además, se tienen estadísticas de las enfermedades no transmisibles en la nación, la prevalencia de sobrepeso y obesidad de personas mayores a quince años ascendió a un 55.8% para el año 2016. Es necesario hacer hincapié que estas condiciones son factores de riesgo para las deformidades como la escoliosis y la espondilolistesis (OPS, 2022).

Según el INE (2023), para el año 2021 se tomaron un total de 305,865 radiografías. Por otro lado, en la sección de morbilidad ambulatoria se registraron un total de 29,695 pacientes con enfermedades del sistema nervioso y 5,157 pacientes con malformaciones congénitas, deformidades y anomalías cromosómicas. Dentro de las cirugías, 331 han sido neurocirugías y 3,028 pacientes han sido sometidos a cirugías ortopédicas. Por último, se registraron 504 operaciones sobre el sistema nervioso y 4,494 operaciones sobre el aparato musculoesquelético, según los datos que se obtuvieron del IHSS.

Debido a la falta de estudios relacionados a la escoliosis y la espondilolistesis, en Honduras es difícil conocer sobre la incidencia de esta, por lo tanto, en la revisión exhaustiva de la literatura se ha tomado en cuenta registros epidemiológicos de otros países. Hacer énfasis en el desarrollo de material científico relacionado a estas deformidades es crucial para conocer la situación actual a nivel nacional y de esta manera proponer herramientas tecnológicas que puedan ser de apoyo en el diagnóstico.

A lo largo de los últimos años en la región Latinoamericana se han desarrollado proyectos que buscan ser de colaboración para brindar evaluaciones diagnósticas eficientes a partir del diseño de algoritmos de clasificación de imágenes radiográficas de la columna vertebral que permitan extraer las características que se distinguen en estas deformidades de la columna vertebral.

Por lo tanto, en el análisis brindado es necesario conocer sobre estos proyectos trabajados con antelación para evaluar su posible aplicación a nivel nacional. De esta forma se podrá tener una visión general de las variables empleadas de modo que este tipo de algoritmos puedan ser replicados e implementados en Honduras. Un ejemplo de esto es la investigación desarrollada por Cumbal (2022) en Ecuador, donde se diseña un algoritmo basado en redes neuronales convolucionales a partir de imágenes radiográficas de la columna vertebral con el fin de calcular el ángulo de desviación de pacientes con escoliosis. Para el entrenamiento del algoritmo se recolectó un conjunto de datos, de radiografías de la columna vertebral proporcionadas por varios centros radiológicos, es obtuvieron un total de 300 imágenes, donde la división realizada consistió en 225 de las imágenes fueron destinadas a un conjunto de entrenamiento y 75 para el conjunto de validación.

La primera fase del proyecto consistió en un etiquetado y desarrollo de preprocesamiento para realizar una limpieza a las imágenes recolectadas. Para el etiquetado de las imágenes se utilizó un software denominado como Visual Geometry Group Image Annotator, de esta manera el investigador ecuatoriano logró etiquetar y seleccionar la región de interés fácilmente. La fase siguiente consiste en el desarrollo del entrenamiento, para esta etapa se definen ciertas variables como ser el número de clases, el número de pasos de entrenamiento por cada época etc. Es importante mencionar que la red neuronal profunda utilizada es la ResNet101, a partir del entrenamiento se prosiguió con la fase de predicciones.

Dentro del trabajo realizado por Cumbal (2022), se destaca el uso de una red neuronal conocida como Red de Región Propuesta (RRP), la cual es empleada para el desarrollo de una máscara que permite obtener las predicciones de objeto. Una vez creada la máscara de la columna vertebral, la fase siguiente consiste en el cálculo del ángulo de Cobb por medio de regresión polinomial. Dentro de los resultados obtenidos en la

investigación se destaca el cálculo de valores estadísticos como media, varianza y desviación estándar a partir de treinta observaciones realizadas por especialistas y por el sistema desarrollado (Tabla 7).

**Tabla 7- Resultados de pruebas para dos muestras relacionadas.**

<b>Valor Estadístico</b>	<b>Grado de Desviación Manual</b>	<b>Grado de Desviación del Sistema</b>
Media	26.86	31.19
Varianza	280.05	391.50
Desviación estándar	16.73	19.78
Observaciones	30	30

Fuente: (Cumbal, 2022)

Así mismo en Colombia, un estudio desarrollado por Ojeda (2022) se destinó al desarrollo de un clasificador basado en redes neuronales para la detección de escoliosis en imágenes por rayos X de la columna vertebral. La metodología empleada en esta investigación consistió en un abordaje de cuatro fases; extracción de imágenes, división del conjunto de entrenamiento y prueba, diseño y construcción de la red neuronal y por último se desarrolla el entrenamiento y validación. Para la etapa de extracción de imágenes se recolectaron radiografías de una base de datos proveniente del sitio Kaggle. El conjunto de imágenes consiste en un total de treinta y nueve casos de escoliosis y para la validación del algoritmo se utilizó un banco de imágenes proporcionado por un radiólogo de un hospital de la ciudad de Popayán, Colombia.

En la exploración se hace uso de una RNC, por medio de la revisión de la literatura existente por ejemplo se hace uso como clasificador a una MSV. Además, se emplea un Análisis Discriminante Lineal (ADL), de modo que se pudiera proporcionar una clasificación supervisada. Dentro de los resultados proporcionados por el investigador, se evalúan métricas de rendimiento como ser la exactitud y la precisión. Al momento de validar el algoritmo propuesto se utilizaron un total de setenta y cinco imágenes con un tiempo de ejecución de diez minutos. Para los resultados se realizaron pruebas con dos versiones del

algoritmo, la primera prueba consistió en dividir al algoritmo en dos clases, dependiendo de la clasificación de las escoliosis conocidas como escoliosis tipo C y tipo S.

Al momento de evaluar las métricas se obtuvo que el porcentaje de exactitud brindado en la clasificación de dos clases fue de 79.2%, por otro lado, se implementó una versión del algoritmo con otra clase de pacientes, específicamente la de pacientes con una columna vertebral normal, obteniendo un porcentaje de exactitud del 94% (Tabla 8).

**Tabla 8- Resultados de exactitud de las dos versiones del clasificador de imágenes radiográficas a partir de RNC.**

<b>Algoritmo</b>	<b>Exactitud</b>
Versión de algoritmo con dos clases	79.2%
Versión de algoritmo con tres clases	94%

Fuente: (Ojeda, 2022)

### **3.2 CONCEPTUALIZACIÓN**

En esta sección del Estado del Arte se presenta la fundamentación teórica de los conceptos claves que se involucran en la investigación, por medio de una descripción de la columna vertebral y las deformidades como la escoliosis y la espondilolistesis, por último, se describen bases conceptuales sobre el aprendizaje automático y sus aplicaciones.

#### **3.2.1 COLUMNA VERTEBRAL**

##### **3.2.1.1 Definición**

La columna vertebral consta de siete vértebras cervicales, doce vértebras torácicas, cinco lumbares, cinco vértebras que conforman el sacro y segmentos coccígeos que forman parte del coxis, siendo un total de treinta y tres vértebras. Existen variaciones en la estructura fundamental de las vértebras en diferentes regiones de la columna vertebral. El cuerpo y el arco son las dos partes principales de una vértebra normal. Los pedículos, la lámina, la apófisis transversa, espinosa y articular superior e inferior conforman el arco vertebral.

Por otro lado, las vértebras en la región cervical son más pequeñas, pero van aumentando en tamaño a medida que llegan al caudal, con vértebras adyacentes articuladas en la faceta articular y discos intervertebrales ubicados entre dos cuerpos vertebrales. El sacro se une distalmente al cóccix, tiene una superficie convexa en el lado dorsal con forma de cuña, está formado por cinco vértebras y se encuentra distal a la quinta vértebra lumbar.

### 3.2.1.2 Anatomía

La columna vertebral forma el esqueleto axial cuando el cráneo y las vértebras en su extremo superior se articulan para sostener la cabeza ósea. Como las porciones proximales de las extremidades superiores e inferiores, respectivamente, la cintura escapular y la cintura pélvica, el esqueleto axial está conectado a ambos. Las costillas y el esternón se combinan para formar la caja torácica, que está formada por las vértebras del segmento torácico que se articulan con ellas.

Entre las funciones de la columna vertebral están que es el eje del cuerpo y el pivote para ciertos movimientos como la rotación, flexión y extensión de diversas regiones del cuerpo humano como la cabeza, el tórax, región lumbar y el cuello. Además, brinda protección al cordón espinal, las meninges y algunos nervios raquídeos y ayuda a mantener la postura y la locomoción (García, 2012).



**Ilustración 1- Segmentos de la Columna Vertebral**

Fuente: (García, 2012)


### 3.2.2 ESCOLIOSIS

#### 3.2.2.1 Definición

Cuando la columna vertebral tiene una desviación de la línea vertical normal se le conoce como escoliosis. Se le considera escoliosis cuando la angulación es de al menos diez grados de la columna en la radiografía posteroanterior asociada con la rotación vertebral. Las causas de esta deformidad varían por diferentes factores y se puede clasificar como

congénita, neuromuscular, idiopática y curvatura de la columna debido a razones secundarias.

El caso más predominante de los tipos de escoliosis es la idiopática. Los antecedentes del paciente, el examen físico y las radiografías son factores imprescindibles para poder realizar una evaluación inicial de la escoliosis para poder determinar si el paciente ocupará consideraciones adicionales. Aproximadamente una cuarta parte de los pacientes con escoliosis idiopática presentan dolor de espalda y en muchas ocasiones presentan dolor en la pared torácica posterior en el lado de prominencia de la costilla (Janicki & Alman, 2007).



**Ilustración 2-Paciente con Escoliosis Idiopática**

Fuente: (Janicki & Alman, 2007)

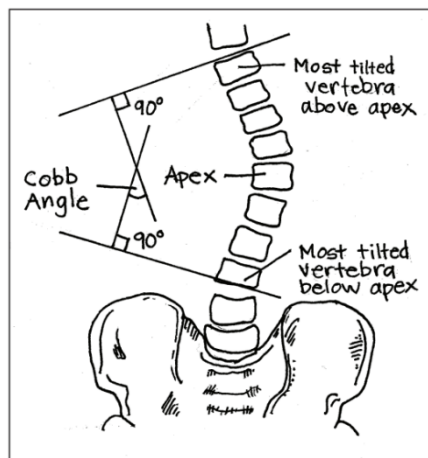
### 3.2.2.2 *Evaluación y Diagnóstico*

Para la evaluación y diagnóstico, se le puede realizar al paciente un examen físico y radiografías. Se debe usar un gráfico de curva de crecimiento que esté estandarizado por edad y sexo para trazar la altura del paciente como parte del examen físico. Las anomalías de la línea media en la piel, como hemangiomas, mechones de cabello y hoyuelos lumbosacros, deben examinarse ya que podrían ser signos de una anomalía de la médula espinal.

Al evaluar visualmente la alineación, se deben verificar las asimetrías tanto manifiestas como encubiertas en la altura de los hombros, las escápulas, los pliegues de los flancos, las crestas ilíacas y las mamas. Un levantamiento debajo de la pierna más corta es útil si hay una discrepancia en la longitud de la pierna para ajustar la escoliosis compensatoria. La determinación de la etapa de Tanner puede ser útil porque el pico de desarrollo puberal (etapas 2-3 de Tanner) es cuando la curva avanza más.

La prueba de inclinación hacia adelante de Adam es una herramienta de evaluación útil. Las palmas de las manos se unen y los brazos se estiran hacia el suelo mientras el paciente se inclina hacia delante por la cintura hasta que la columna quede horizontal con el suelo. La asimetría en el contorno, que se indica por un lado de la espalda más alto que el otro, es examinada por el profesional de la salud cuando mira al paciente desde atrás. El escoliómetro es la herramienta utilizada para medir el ángulo de rotación vertebral. Este es colocado perpendicular al eje longitudinal del cuerpo y es movido a través de la columna vertebral.

Las radiografías no son imprescindibles para una evaluación de escoliosis, ya que utilizan radiación para poder visualizar la columna vertebral. Las altas dosis de radiación pueden ocasionar efectos adversos en el paciente. Sin embargo, las radiografías pueden ser utilizadas para determinar el grado de la curvatura de la escoliosis por medio del ángulo de Cobb. Este es medido por medio de dos líneas que se intersecan dibujadas perpendicularmente a la vértebra superior e inferior más inclinadas.




**Ilustración 3-Medición Ángulo de Cobb**

Fuente: (Burton, 2013)

Durante los períodos de desarrollo esquelético, es más probable que se produzca una progresión de la curva. El estado de la menarquia, la edad del paciente al comienzo y el signo de Risser son solo algunas de las variables que afectan el potencial de crecimiento restante. El grado de osificación del proceso de la cresta ilíaca, que comienza

anterolateralmente y se desplaza posteromedialmente con la madurez, es lo que determina el signo de Risser, que es un indicador de la madurez esquelética.

Al determinar la probabilidad de progresión de la curvatura, es útil el estado de la menarquia en combinación con el grado de Risser. Las personas con el estadio 2 de Risser tenían un 50 % de posibilidades de progresar antes de la menarquia, en comparación con un 20 % de posibilidades en las personas posmenárquicas (Burton, 2013).



**Ilustración 4-El Signo de Risser**

Fuente: (Burton, 2013)

### 3.2.2.3 *Tratamiento*

Dentro de los tratamientos para la escoliosis se tienen la ortesis (corsé), cirugía y la observación seriada. Antes de seleccionar el tratamiento adecuado para cada uno de los casos de escoliosis es necesario tener en cuenta factores como la etiología de la deformidad, los riesgos de la evolución y las consecuencia y riesgos del tratamiento al que el paciente se someterá.

Varios pacientes tienen una baja probabilidad de experimentar un empeoramiento de las condiciones. Esto se puede atribuir a tener una curvatura leve o moderada en su crecimiento esquelético, como una niña de 16 años con una curva de 25° y Risser IV, o tener una escoliosis muy leve, pero con potencial para un mayor crecimiento, como un niño de 12 años con curva de 15° y Risser II. En ambos casos, no es necesario un tratamiento activo. El paciente de 16 años con curva leve puede ser dado de alta, mientras que el segundo caso requiere seguimiento anual por el riesgo de que la curva se intensifique durante el

crecimiento. A medida que comienza el crecimiento acelerado de la preadolescencia y la frecuencia de las citas de seguimiento se puede aumentar cada seis meses.

La efectividad del uso de esta ortesis es determinada por el ajuste, diseño al paciente y el tiempo de uso que se requiera. Este se utiliza para parar la progresión de la curva para evitar que el paciente se someta a una cirugía. Para la utilización de un corsé, la curva de la columna vertebral debe de cumplir con varios principios para la aplicación, sin embargo, se presentan situaciones que limitan su indicación como la piel de resistencia disminuida, obesidad, lordosis dorsal, entre otros.

Existen tratamientos quirúrgicos para poder ayudar al paciente con escoliosis. La cirugía de las deformidades de la columna tiene una serie de particularidades y objetivos comunes para las diferentes etiologías. Estas últimas están relacionadas principalmente con la etapa del crecimiento del niño y la severidad, así como con la causa de la deformidad. La clasificación de Lenke ayuda a poder seleccionar a aquellos pacientes aptos para la artrodesis (fijación) del tórax selectiva, lo que cumple con la máxima del cirujano de escoliosis: mantener la movilidad lumbar siempre que sea posible (Pantoja & Chamorro, 2015).



**Ilustración 5-Fijación Posterior de Escoliosis**

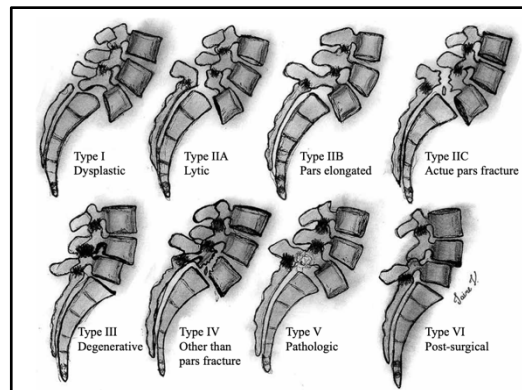
Fuente: (Pantoja & Chamorro, 2015)

### 3.2.3 ESPONDILOLISTESIS

#### 3.2.3.1 Definición

La espondilolistesis es el trastorno que es provocado cuando existe el deslizamiento de un cuerpo vertebral sobre el otro por debajo. La espondilolistesis se puede clasificar en seis tipos. El tipo I que incluye la displasia del sacro o del arco neural L5 que puede resultar posteriormente en elongación. El tipo II que es un defecto en el par interarticular con lisis, elongación o fractura aguda. El tipo III que es el resultado de la osteoartritis que conduce al deslizamiento de las vértebras. El tipo IV es secundario a una fractura aguda de los elementos posteriores u otras estructuras donde el par interarticular no está comprometido. El tipo V que se asocia a la incompetencia de los elementos posteriores o procesos patológicos óseos. Por último, el tipo VI que es el resultado de la pérdida de elementos posteriores debido a la cirugía.

El deslizamiento vertebral suele ocurrir en el segmento L4 a L5. Generalmente es asintomática y no existe relación clara entre los síntomas y el grado de listesis, aunque el de degeneración aumenta el riesgo de progresar a estenosis espinal lumbar y causar síntomas. Además, esta deformidad es la causa del dolor lumbar en la mayoría de casos que proviene de las articulaciones degeneradas y subluxación, la inestabilidad segmentaria que provoca tensión en las cápsulas y ligamentos de las articulaciones (García-Ramos et al., 2020).



**Ilustración 6-Tipos de Espondilolistesis**

Fuente: (García-Ramos et al., 2020)

### 3.2.3.2 *Evaluación y Diagnóstico*


Los estudios de imagen con tecnología avanzada son imprescindibles para analizar si es necesario una intervención quirúrgica, pero su función y objetivo principal es confirmar si el paciente cuenta con la deformidad de espondilolistesis. En presencia de un arco neural intacto, las propiedades con las que cuenta una radiografía simple incluyen el descubrimiento en una vista lateral de desplazamiento hacia delante de las vértebras L4 sobre L5, L5 sobre S1 o L3 sobre L4. La apófisis espinosa avanza con el cuerpo vertebral en esta deformidad porque el arco neural está intacto.

Esto resulta en apófisis espinosas mal alineadas, que se pueden ver en radiografías laterales. Los hallazgos adicionales, como el estrechamiento del espacio discal, el signo de vacío, la esclerosis de la placa terminal, los osteofitos peridiscales y la esclerosis y la hipertrofia facetaria, suelen ser compatibles con un proceso degenerativo de larga duración. La hemisacralización de la vértebra L5 se puede ver con frecuencia, pero no siempre, en una radiografía anteroposterior.

Según la presentación del paciente y los hallazgos clínicos, se analizará si se tendrá que realizar otros exámenes o estudios de imágenes adicionales. La claudicación neurológica o radiculopatías significativas y progresivas, así como la suposición clínica de que exista la posibilidad de encontrar otra afección, como una enfermedad metastásica, puede ser la causa, son factores que indican la necesidad de más imágenes. La presencia de molestias en la vejiga o el intestino es una indicación absoluta.

La tomografía computarizada (TC), la mielografía, la tomografía computarizada mejorada con material de contraste y los estudios realizados por resonancia magnética son alternativas de imágenes. Se puede realizar una tomografía computarizada de la columna con o sin contraste intratecal. Se requiere de una MRI o una TC para poder visualizar con mayor detalle el elemento neural en pacientes con signos y síntomas que padecen de estenosis espinal.

Se pueden elegir estudios adicionales como gammagrafía ósea con técnica, especialmente en casos de sospecha de tumor metastásico, y estudios de electrodiagnóstico en caso de sospecha de trastorno neurológico sistémico (Kalichman & Hunter, 2008).



**Ilustración 7-Esquema de Clasificación de Espondilolistesis: Meyerding y Taillard**

Fuente: (Kalichman & Hunter, 2008)

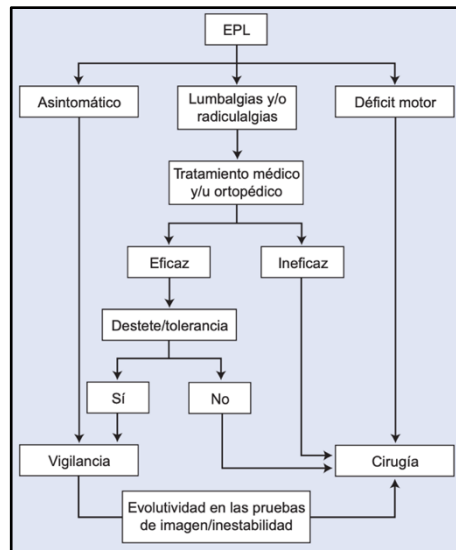
### 3.2.3.3 *Tratamiento*

Para restaurar la estática espinal mejorada, se deben corregir las anomalías morfológicas causadas por la espondilolistesis. Se requiere cirugía para abordar los componentes anterior y posterior de la estabilidad de la columna vertebral que fallaron después de la fusión. La liberación del nervio es posible gracias a la subsiguiente descompresión y reducción de la listesis.

Solo el 10-20% de los diagnósticos de espondilolistesis se operan quirúrgicamente, lo que la convierte en una condición rara. La clínica y su reacción a la atención médica y ortopédica, más que el grado o la gravedad de las displasias, dictan el curso de acción quirúrgica potencial. Como resultado, un paciente asintomático que presenta una gran espondilolistesis desplazada generalmente tiene un resultado clínico positivo sin cirugía. Solo cuando una terapia conservadora adecuada ha fallado en un paciente con síntomas o que muestra signos evolutivos e inestabilidad, está indicada la cirugía.

La laminectomía y la apertura de los procesos frente a las raíces afectadas constituyen la descompresión del nervio. Si es necesario, se retiran el nódulo fibrocartilaginoso y el gancho ístmico a nivel de la lisis. Para eliminar una hernia de disco o un bulto de disco que está en conflicto con la raíz, se realiza una discectomía bilateral después de coagular las venas epidurales. Para que la raíz se libere de su foramen y sea más fácil introducir los dispositivos intersomáticos, esta discectomía debe ser evidentemente bastante lateral. En la espondilolistesis displásica, cuando las raíces S1 sufren tensión debido a la protuberancia de la meseta sacra, es posible que sea necesario eliminar la prominencia S1 con un osteotomo.

La implantación de tornillos pediculares es más rápida y se realiza en espondilolistesis de grado menor antes del procedimiento de descompresión subsiguiente, protegiendo los tejidos nerviosos de posibles daños por herramientas. La colocación de tornillos pediculares puede ser más difícil en casos de espondilolistesis de alto grado, y primero se deben descomprimir los componentes nerviosos para facilitar el control endocanalicular del pedículo atornillado. Los tornillos de tracción se pueden insertar en los criterios de la vértebra para una mejor reducción (Freppel et al., 2009).



### Ilustración 8-Tratamiento Quirúrgico de la Espondilolistesis

Fuente: (Freppel et al., 2009)

#### 3.2.4 APRENDIZAJE PROFUNDO

En las ciencias biológicas, ya se está utilizando una forma de aprendizaje automático que permite a las computadoras resolver problemáticas de percepción, como el reconocimiento de imágenes y voz. Las redes neuronales artificiales profundas, las cuales son un método de aprendizaje profundo, utilizan varias capas de procesamiento para poder descubrir patrones y estructuras en conjuntos de datos grandes. Cada una de estas capas aprende un concepto de los datos sobre los que se basan las capas posteriores; es por ello, que entre más alto es el nivel, más abstracto es el concepto que aprenden.

El Deep Learning, como se le conoce, no depende del procesamiento previo de datos y extrae características de manera automática. Por ejemplo, una red neuronal encargada de interpretar formas aprendería a reconocer bordes simples en la primera capa y luego

agregaría el reconocimiento de formas más complejas compuestas por esos bordes en capas posteriores. Además, será invaluable en el contexto de los grandes datos, ya que extrae información de alto nivel de grandes volúmenes de datos (Rusk, 2016).

#### 3.2.4.1 *Redes Neuronal Convolutional (CNN)*

Es una forma de red neuronal artificial de aprendizaje supervisado que procesa sus capas replicando la corteza visual del ojo humano para reconocer distintas propiedades en la entrada, lo que le permite identificar cosas. Las funciones principales de los CNN incluyen la detección/categorización de objetos, la clasificación de escenas y la clasificación de imágenes en general.

Las capas convolucionales se consideran una colección de filtros conocidos como campos receptivos, que se modifican para extraer características de una señal. A diferencia de una red neuronal típica, en la que cada neurona de una capa se vincula con todas las neuronas de la otra, las neuronas CNN se comparten a través de filtros que permiten obtener información de las imágenes de entrada.

Cada capa de CNN es un bloque con tres variables principales: entrada, pesos y salida. Un aspecto crucial de estas capas es que la salida de una capa se convierte en la entrada de la siguiente. Este proceso es secuencial y no lineal, con cada capa desempeñando un papel importante y diferente para poder tener un resultado. El propósito básico de CNN es extraer patrones, en este caso en imágenes, para lo cual emplean entrenamiento sin supervisión (Cifuentes et al., 2019).

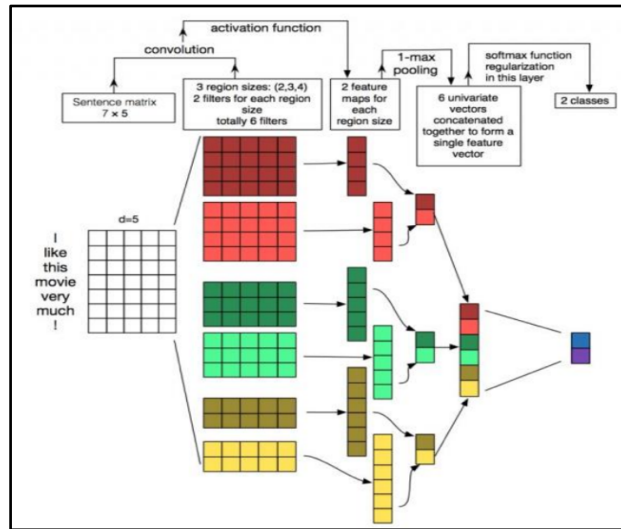
#### 3.2.4.2 *Partes y Estructura*

Varios núcleos de convolución se deslizan juntos para crear una colección de características paralelas conocida como una capa convolutional. Con el fin de proyectar la información desde el campo receptivo hacia un elemento del mapa de características, se realiza una operación de producto y suma correspondiente entre el núcleo de convolución y la imagen de entrada en cada posición deslizante. Las dimensiones del núcleo de convolución son significativamente más pequeñas que el tamaño de la imagen de entrada. Para calcular el tamaño de la convolución (mapa de características) se utiliza la siguiente:

$$\text{Dim}(H_1, W_1, D_1) = ((H + 2Zp - k_1) / Z_s + 1, (W + 2Zp - k_2) / Z_s + 1, K_D)$$

## Ecuación 1- Ecuación para calcular el Mapa de Características

Fuente: Yang & Li (2017)



## Ilustración 9-Estructura de una Red Neuronal Convolutiva

Fuente: (Yang & Li, 2017)

El propósito de la función de activación es activar las propiedades de las neuronas a través de la función para preservar y mapear características, no para desactivarlas. La salida de una neurona particular después de una combinación específica de entradas se determina mediante la función de activación. Se proporciona la función de activación para la conversión no lineal utilizando la suma ponderada de los valores de entrada de la red lineal. Con el fin de permitir que la red neuronal aborde problemas no lineales, esta etapa tiene como objetivo mantener las características y reducir cierta redundancia de datos.

La capa de agrupación, también conocida como capa de muestreo descendente, combina la salida de un grupo de neuronas frontales con las neuronas individuales subyacentes. Después de la activación no lineal, la capa de agrupación se utiliza para reducir la cantidad de parámetros y evitar el sobreajuste. Además, actúa como una técnica de suavizado para eliminar ruidos no deseados. La capa de agrupación genera un mapa de características de tamaño cincuenta por cincuenta para lograr el objetivo de reducir la cantidad de datos. Las dimensiones de la capa de agrupación se pueden calcular utilizando la siguiente ecuación:

$$\text{Dim}(H_2, W_2, D_2) = ((H_1 - k) / Z_s + 1, (W_1 - k) / Z_s + 1, D_n)$$

**Ecuación 2- Cálculo para encontrar las dimensiones de la capa de agrupación.**

Fuente: (Yang & Li, 2017)

Como clasificador, se utiliza la capa densa totalmente conectada. Esta ayuda a traducir las características aprendidas al espacio de etiquetas de muestra, procedimientos como la capa convolucional, la capa de agrupación y la capa de función de activación sirven para mapear la entrada en bruto al espacio de características ocultas.

El grado de discrepancia entre el valor proyectado por el modelo y el valor real se calcula mediante la función de pérdida. La función de pérdida mejora la robustez del modelo al reducir su valor. Es un elemento crucial tanto en las funciones de riesgo estructural como en las funciones de riesgo empírico. Forma el núcleo de estas funciones. Es esencial para mejorar la precisión del modelo y la optimización de este. La función de pérdida se representa por medio de la siguiente ecuación (Yang & Li, 2017):

$$L(Y, f(x)) = |Y - f(x)|$$

**Ecuación 3- Función de pérdida.**

Fuente: (Yang & Li, 2017)

**3.2.4.3 Convolución**

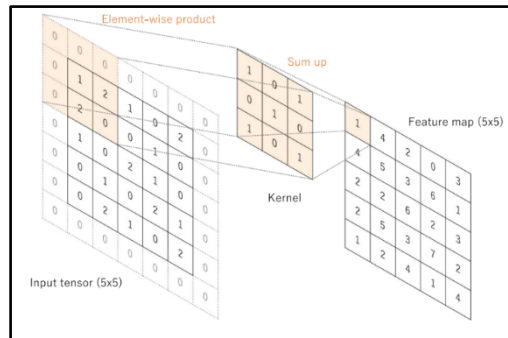
En la capa de convolución se extraen características que contienen operaciones lineales y no lineales, en otras palabras, operación de convolución y función de activación es una operación lineal especializada utilizada para extraer características, donde se aplica una matriz de números (núcleo) a través de la entrada, que es una matriz de números, llamado tensor. Se calcula un producto por elementos entre cada elemento del núcleo y el tensor de entrada en cada ubicación del tensor y se suma para obtener el valor de salida en la posición correspondiente del tensor de salida conocido como mapa de características.

Este proceso se repite aplicando diferentes núcleos para poder formar varios mapas, representando diferentes características de los tensores de entrada. El tamaño y la cantidad de kernels son parámetros que definen la operación de convolución. La técnica de convolución descrita anteriormente evita que el centro de cada núcleo se superponga al elemento más externo del tensor de entrada y minimiza la altura y el ancho del mapa de características de salida en comparación con el tensor de entrada.

El relleno es una estrategia para abordar este problema que implica agregar filas y columnas de ceros a cada lado del tensor de entrada para ajustar el centro de un kernel en el elemento más externo y mantenerlo constante en el plano. dimensión a través del proceso de convolución. Los diseños modernos de CNN suelen utilizar cero rellenos para mantener las dimensiones en el plano para las capas posteriores. Sin relleno con ceros, siguiendo el procedimiento de convolución, cada mapa de características subsiguiente sería más pequeño. Zancada lleva como nombre a la distancia entre dos posiciones sucesivas de kernel, además define la operación de convolución.

Uno de los parámetros clave de una operación de convolución es el peso compartido que permite que los patrones de características locales extraídos por la traducción de los núcleos sean invariantes a medida que los núcleos viajan por cada una de las posiciones de la imagen y detectan patrones locales aprendidos. También, aprenden jerarquías espaciales de patrones de características mediante la reducción de muestreo con una operación de agrupación y aumenta la eficiencia del modelo al reducir la cantidad de factores para aprender.

En la capa de convolución en el proceso de entrenamiento de un modelo CNN consiste en identificar los núcleos que funcionan mejor para una tarea en específico en función de un conjunto de datos de entrenamiento determinado. Los únicos parámetros que se aprenden de manera automática durante el proceso de entrenamiento en la capa de convolución son los kernels. La zancada, el relleno, el número y tamaño de los núcleos son hiperparámetros que se deben de establecer antes de que comience el proceso de entrenamiento (Yamashita et al., 2018).



**Ilustración 10-Ejemplo de una Convolución**

Fuente: (Yamashita et al., 2018)

### 3.2.4.4 Agrupamiento


Hay direcciones para mejorar la capa de pooling de las CNN las cuales son learning-based pooling, hand-crafted pooling y probabilistic pooling. El learning-based pooling minimiza el error de entrenamiento durante dicha etapa. La agrupación convolucional se propuso como alternativa para la operación de agrupación. La red convolucional fue diseñada de acuerdo con el hallazgo de que el max pooling puede ser reemplazado por una capa convolucional con mayor zancada sin pérdida de precisión en la tarea de reconocimiento de imágenes.

Se propuso la operación de mixed pooling para incorporar diferentes operaciones de agrupación en esta capa, combinando funciones de pooling tradicionales y de no aprendizaje de pooling máxima y de promedio. Las operaciones de agrupación mixta proporcionan un impulso en la invariancia de propiedades relativas a la agrupación tradicional.

La mayoría de las operaciones de pooling conocidas son métodos "hand-crafted". Por ejemplo, max pooling obtiene el máxima de la región, en cambio, la agrupación promedio extrae el valor promedio de la región. El pooling piramidal espacial fue diseñado para tratar con imágenes de tamaño arbitrario. Además, la operación de escala múltiple puede mejorar la invariancia de escala. No obstante, debe de proceder de una capa de conexión completa, dando como resultado más cantidad computacional.

Por último, el probabilistic pooling que propone una agrupación estocástica en el que se debe de elegir el valor máximo en cada región de agrupación en el que a su vez es reemplazado por una forma de muestreo sesgado por tamaño. Por otro lado, también hay

una forma particular de max-pooling conocida como max-pooling fraccional que reduce el tamaño espacial de la imagen por un factor  $\alpha$  con  $2 > \alpha > 1$ . La agrupación estocástica y el max-pooling introducen un grado de aleatoriedad lo que le da ventaja a comparación a otros tipo de agrupación ya que evita el sobreajuste (Sun et al., 2017).



**Ilustración 11-Agrupamiento Tradicional**

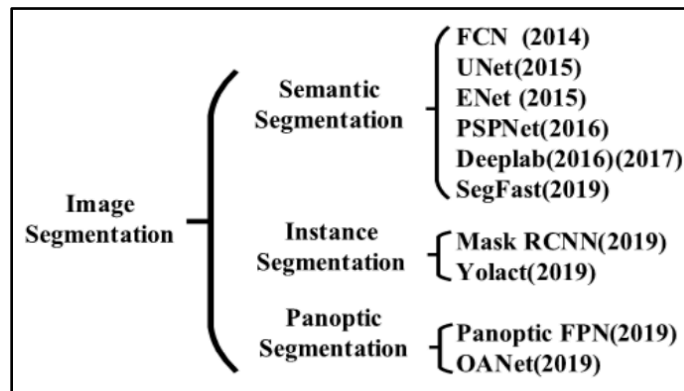
Fuente: (Sun et al., 2017)

### 3.2.4.5 *Funcionamiento y Aplicaciones*

La red neuronal convolucional se puede utilizar para una gran cantidad de datos y obtener un resultado prometedor, ya que es usado en aplicaciones en una, dos hasta en multidimensiones. Comenzando con las aplicaciones en una dimensión, se utiliza para predecir series temporales de datos como en el pronóstico del tiempo, señales de electrocardiogramas o predicción del flujo del tráfico. También, en identificación de señales discriminando la señal de entrada de acuerdo con la característica que la red neuronal convolucional aprendió en el entrenamiento. A esto, se refiere con identificación de daños estructurales o fallas en algún sistema.

Dentro aplicaciones en dos dimensiones, se encuentra la clasificación de imágenes habiendo muchos softwares utilizados como LeNet-5, AlexNet, entre otros. Además, GoogLeNet y VGGNets que son estructuras de red más profundas que en comparación a otros softwares, brindan mayor precisión en las tareas de clasificación. Además, se puede aplicar para clasificación de imágenes médicas como por ejemplo clasificación de deformidades de la columna vertebral y para detectar objetos tomando como ruta dos

etapas fundamentales. Dentro de estas etapas, primeramente, se seleccionan las propuestas de región para luego la red neuronal convolucional clasifique los objetos (Li et al., 2022).



**Ilustración 12- Aplicación de CNN en Segmentación de Imágenes**

Fuente: (Li et al., 2022)

#### 3.2.4.6 Modelos Pre-entrenados de CNN


La inteligencia artificial utiliza una variedad de técnicas de aprendizaje que pueden absorber una gran cantidad de datos, lo que permite que el algoritmo identifique numerosos patrones a medida que aprende. Los desarrolladores pueden ahorrar tiempo utilizando estos modelos de aprendizaje en lugar de pasar horas sentados programando y considerando todos los casos posibles. Existen cuatro formas distintas que contiene el aprendizaje automático, las cuales son:

- Aprendizaje supervisado: Estos modelos requieren el etiquetado manual por parte de los humanos. El modelo necesita tanto los valores de entrada como sus salidas asociadas (etiquetas) para que el algoritmo pueda aprender. El algoritmo puede aprender a reconocer patrones y conexiones entre las características de entrada y las salidas deseadas al mostrárselo estos ejemplos durante el entrenamiento. Una vez entrenado, el sistema puede utilizar esta información para ejecutar tareas sin ejemplos etiquetados y generar predicciones sobre nuevos datos.
- Aprendizaje no supervisado: Estos modelos solo necesitan datos de entrada que contengan características de la circunstancia particular; no requieren datos etiquetados. El objetivo de este modelo es simular la distribución o estructura de los datos bajo la premisa de que se dividen en varios grupos categorizados.

- Aprendizaje semi supervisado: Este método se encuentra en un punto intermedio entre el aprendizaje supervisado y no supervisado. Con respecto a su salida, puede ser entrenado utilizando datos etiquetados o no etiquetados. Por lo tanto, cuando se proporciona un conjunto de datos de entrada, buscamos obtener la salida correspondiente a ese conjunto.
- Aprendizaje reforzado: El método de aprendizaje no supervisado utilizado en el aprendizaje por refuerzo solo recibe entradas o refuerzos, como recompensas o penalizaciones. Para maximizar su aprendizaje en esa tarea, debe aprender a mapear contextos de acciones con respecto a la función de recompensa (Cumbal, 2022).

Dentro de algunos los modelos pre-entrenados existen:


1. ResidualNet (ResNET101): La red convolucional profunda residual, fue creada por K. He, X. Zhang, S. Ren y J. Sun. Obtuvo el primer lugar tanto en la competición de detección y segmentación Microsoft COCO 2015 como en el desafío de clasificación de imágenes ILSVRC 2015. ResNet tiene tres categorías diferentes: ResNet50, ResNet101 y ResNet152. El uso del aprendizaje residual o el desarrollo de "conexiones saltadas" entre bloques convolucionales, es un concepto clave en este trabajo. Al reducir y evitar su desaparición, estas conexiones saltadas mejoran significativamente el flujo de gradientes. Esto permite utilizar redes mucho más profundas para un entrenamiento considerablemente más profundo. En el conjunto de validación, ResNet alcanza una precisión del 76,4% en el top uno y del 92,9% en el top cinco (Mahajan et al., 2022).



**Ilustración 13-Aprendizaje Residual a través de Conexiones de Salto**

Fuente: (Mahajan et al., 2022)

2. Densely Connected Convolutional Network (DenseNet201): La red convolucional densamente conectada (DenseNet201), que fue propuesta por G. Huang, es un modelo mejorado en términos del flujo de información entre capas con una nueva estructura de conexiones. Incluye un total de 201 capas. Los gradientes de las capas sucesivas pasan directamente a través de la función de identidad de las conexiones saltadas establecidas por ResNet para evitar las transformaciones no lineales. La suma directa de la función de identidad y la salida restringe el flujo de información. El diseño de DenseNet ha intentado abordar este problema. La cantidad de parámetros se ha reducido significativamente y este estudio también promueve la reutilización de características (Mahajan et al., 2022).
3. Single Short MultiBox Detector (SSD512): Se utiliza una red base inicial para construir el Single Short Multibox Detector, que posteriormente se acorta con varias capas convolucionales. Incorpora una sucesión de capas convolucionales cada vez más delgadas para permitir predicciones de detección en diversas escalas. Se crean varios cuadros previos o predeterminados con diferentes tamaños y relaciones de aspecto para cada celda en el mapa de características mediante el mosaico frecuente del mapa de entrada para cada celda del mapa de características. Se utiliza un umbral del índice de Jaccard para comparar estos datos de cuadros previos con las cajas de verdad y clasificarlos como muestras negativas o positivas (Mahajan et al., 2022).



**Ilustración 14-Estructura de SSD**

Fuente: (Mahajan et al., 2022)

4. EfficientNet: La arquitectura EfficientNet, que ofrece modelos escalables hasta EfficientNet-b7, tiene un diseño base de EfficientNet-b0. El diseño de la arquitectura se basa en el concepto de escalado compuesto, que ajusta de manera uniforme la profundidad, el ancho y la resolución de entrada de la red utilizando coeficientes de escalado predefinidos (Fraiwan et al., 2022).
5. MobileNets: Con un tamaño de imagen de entrada de  $[224 \times 224 \times 3]$ , MobileNets contiene un total de 53 capas. Es una red diseñada para entornos donde las personas se desplazan. Para reducir los requisitos de memoria, el modelo debe ser eficiente y compacto. Esto se logra mediante el uso de capas de cuello de botella residuales invertidas, que requieren cálculos que pueden programarse de manera eficiente con un conjunto de trabajo reducido (es decir, la cantidad de tensores que se almacenan simultáneamente en la memoria) (Fraiwan et al., 2022).

## IV. METODOLOGÍA

En este capítulo se expone la metodología utilizada en el desarrollo de esta investigación. Donde se define el enfoque de la investigación, el alcance de esta, el diseño de la investigación y las variables tanto dependientes como independientes. Además, de los métodos empleados para el alcance de los objetivos propuestos.

### 4.1 ENFOQUE

El enfoque de la investigación es cuantitativo ya que se midieron métricas de desempeño como la precisión, la exactitud, la sensibilidad y el puntaje F1 del algoritmo para identificar la validez, lo útil y lo eficaz que puede llegar a ser al momento de la clasificación de las imágenes brindadas. El diseño es experimental ya que se cambiaron las variables teniendo control total de ellas. Además, se entrenó el modelo y se modificaron las variables para poder probar si estas alteraciones producen una mejora en el algoritmo.

Por otro lado, según Sampieri et al. (2014), un alcance exploratorio se define para un tema que es novedoso y poco estudiado, por lo que se cuentan con muchas interrogantes ya que no se ha abordado en otros estudios o investigaciones.

El alcance de investigación es exploratorio ya que en Honduras no se han realizado investigaciones directamente sobre estas dos deformidades utilizando un clasificador aplicando redes neuronales. Sería un gran avance para la medicina poder aplicar aprendizaje profundo para detectar de manera eficiente y eficaz ciertas patologías como lo son la escoliosis y la espondilolistesis.

**Tabla 9- Metodología de Investigación**

<b>Metodología de Investigación</b>	
<b>Enfoque</b>	Cuantitativo
<b>Tipo de diseño</b>	Experimental
<b>Alcance</b>	Exploratorio

Fuente: Elaboración Propia.

## 4.2 VARIABLES DE INVESTIGACIÓN

Se le conoce como variable a una cualidad que presenta una variación y se puede observar o medir. Cuando una variable está relacionada con otra, es decir, cuando es parte de una hipótesis o una teoría, esta adquiere importancia para la investigación científica. En este contexto, a veces se les denomina construcciones o constructos hipotéticos (Sampieri et al., 2014).

### 4.2.1 VARIABLES DEPENDIENTES

En esta investigación, las variables dependientes son las métricas de desempeño a utilizar que varían dependiendo de cómo se entrene el algoritmo de aprendizaje profundo orientado a la clasificación de imágenes. Entre las métricas utilizadas se pueden mencionar las siguientes:

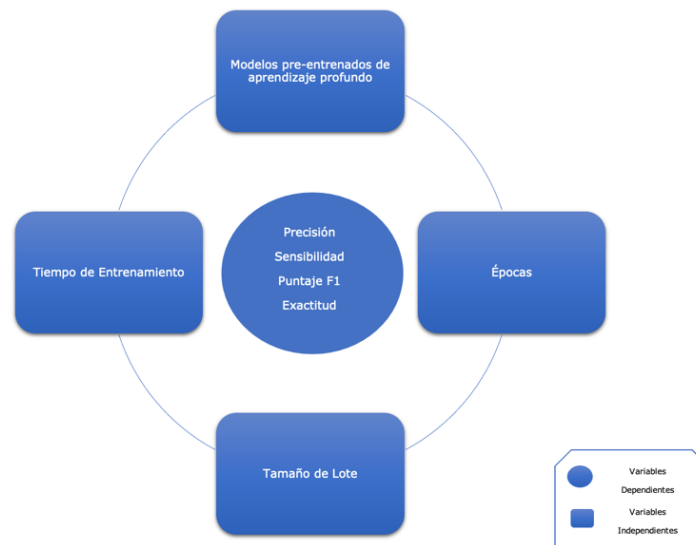
- Precisión: este concepto hace referencia a la proporción de elementos que el sistema devuelve y que son exactamente correctos (Derczynski, 2016).
- Sensibilidad: es la medición total de todos los objetos que fueron detectados de manera correcta (Bautista-Hernandez et al., 2022).
- Puntaje F1: se refiere a la medida armónica de precisión y sensibilidad. Además, expresa la precisión de la clasificación en conjuntos de datos desequilibrados (Fraivan et al., 2022).
- Exactitud: se refiere al porcentaje de todos los resultados verdaderos de las muestras de prueba (Abdullah et al., 2018b)

### 4.2.2 VARIABLES INDEPENDIENTES

Las variables independientes son aquellas variables que a pesar de que se presenten cambios en el algoritmo, estas no llegan a sufrir ningún cambio. Se tienen factores que llegan a afectar las variables dependientes, entre ellas se pueden mencionar las siguientes:

- Modelos pre-entrenados de aprendizaje profundo: son las redes neuronales que se entrenan previamente para que puedan ser utilizadas y aplicadas para realizar tareas de aprendizaje profundo como ser la clasificación de imágenes.
- Épocas: es la cantidad de veces que el algoritmo aprendió de todos los ejemplos durante la fase de entrenamiento.

- Tamaño de lote: se refiere a la cantidad de ejemplos de entrenamiento que ayudan a actualizar los pesos del algoritmo en cada uno de los pasos en la fase de entrenamiento.
- Tiempo de entrenamiento: es el periodo que toma para ajustar los pesos y parámetros del algoritmo utilizando datos de entrenamiento y depende de factores como el tamaño de la red, la cantidad de datos de entrenamiento, entre otros.



**Ilustración 15- Variables Dependientes e Independientes**

Fuente: Elaboración Propia

### 4.3 TÉCNICAS E INSTRUMENTOS APLICADOS

En esta sección se describen las técnicas e instrumentos, estas son herramientas indispensables para que los resultados obtenidos sean confiables y tengan validez. Además, fueron de mucha importancia para poder obtener datos precisos y tener una interpretación certera.


#### 4.3.1 TÉCNICAS

Entre las técnicas a utilizar para poder clasificar las imágenes según el diagnóstico, ya sea escoliosis, espondilolistesis o sano, se utilizaron algoritmos del estado del arte como ser MobileNetV3-small, MobileNetV3-large, EfficientNetV2B0, EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2. Cada uno de estos son modelos pre-entrenados

utilizan aprendizaje profundo para lograr identificar y clasificar un conjunto de imágenes de una determinada base de datos.

#### 4.3.1.1 *Arquitectura de MobileNetV3*

MobileNet utiliza una amalgama de cuellos de botella inversos procedentes de MobileNet V2 y bloques de Squeeze-and-Excitation extraídos de las Redes de Squeeze-and-Excitation. Estos cuellos de botella comprenden una capa de convolución de expansión 1x1, una capa de convolución 3x3 en profundidad y posteriormente, una capa de proyección 1x1. La capa de expansión 1x1 de la última etapa se ha desplazado más allá de la capa de agrupación. Esto permite que la capa 1x1 funcione en un mapa de características 1x1 en lugar de 7x7, lo que disminuye la latencia y el tiempo de cómputo. La cantidad de filtros en la etapa inicial se ha reducido a 16 para la convolución 3x3, en contraste con otros modelos de MobileNet que de manera predefinida tenían 32 filtros (Howard et al., 2019).




**Ilustración 16- Arquitectura de modelo pre-entrenado MobileNetV3.**

Fuente: (Howard et al., 2019)

#### 4.3.1.2 *Arquitectura de EfficientNetV2*

En este modelo, es necesario contar con una buena red de referencia ya que la escalación del modelo no cambia los operadores de capa  $F_i$ . Se necesita una red de referencia aprovechando una búsqueda de arquitectura neural con varios objetivos que busca optimizar la precisión y operaciones de punto flotante por segundo (FLOPS). A diferencia de enfoques anteriores, este se centra en optimizar FLOPS en lugar de la latencia, ya que no está dirigido a un hardware específico. El bloque de construcción de EfficientNet

es el mobile inverted bottleneck MBConv, al que se le incluye la técnica de optimización de squeeze-and-excitation (Tan & Le, 2019).



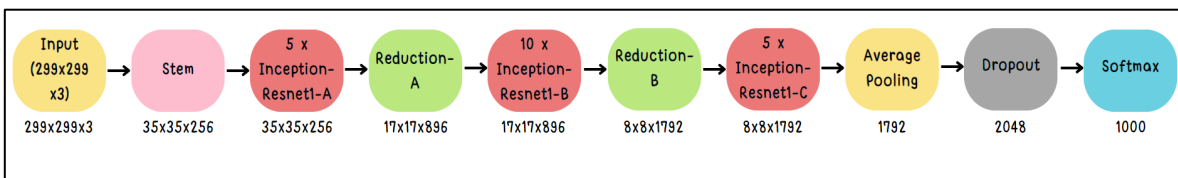
**Ilustración 17- Arquitectura de modelo pre-entrenado EfficientNetV2.**

Fuente: (Tan & Le, 2019)

#### 4.3.1.3 *Arquitectura de InceptionResNetV2*

El objetivo de la arquitectura de Inception es el de encontrar cómo se puede cubrir y aproximar una estructura local escasa óptima en una red convolucional de visión, con la ayuda de componentes densos disponibles. Es por ello, que se necesita encontrar la construcción local óptima y repetirla espacialmente. Se sugiere que dicha construcción sea capa por capa para poder analizar las estadísticas de correlación de la capa última y agruparlas en unidades con alta correlación.

Por otro lado, cada unidad de la capa anterior corresponde a una región de la imagen de entrada y se agrupan en bancos de filtros. Por consiguiente, se tendrán varios grupos concentrados en una sola región y se pueden llegar a cubrir con una capa de convoluciones de 1x1 en la siguiente capa. No obstante, puede haber un número menor de grupos más dispersos espacialmente que se pueden cubrir con convoluciones más grandes y habrá un número decreciente de parches en regiones más grandes. Para evitar cualquier tipo de inconveniente con la alineación de parches, las encarnaciones actuales de este modelo están limitadas a tamaños de filtro 1x1, 3x3 y 5x5 (Szegedy et al., 2015).



**Ilustración 18- Arquitectura de modelo pre-entrenado InceptionResNetV2.**

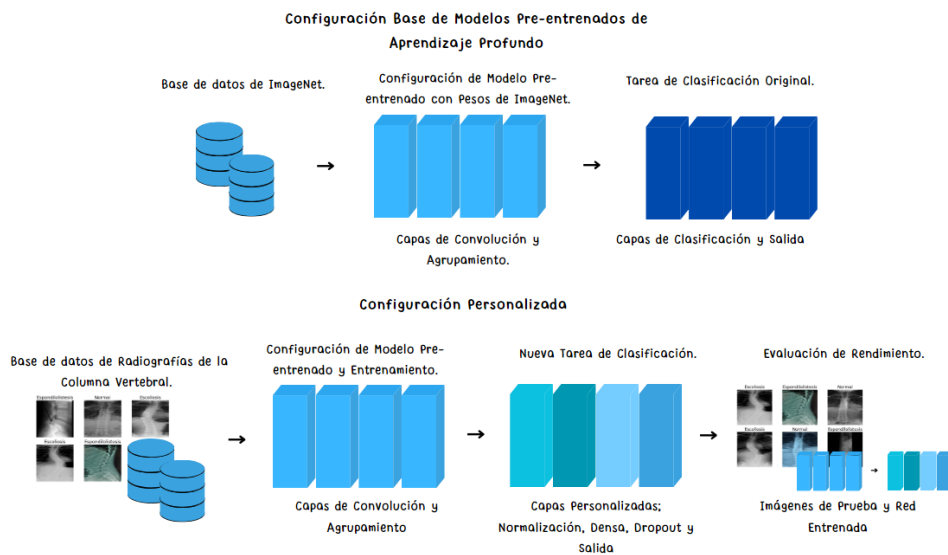
Fuente: (Szegedy et al., 2015)

#### 4.3.1.4 *Abordaje del proceso de aprendizaje de transferencia profunda*

Debido a que esta investigación se plantea el uso de diversos modelos pre-entrenados de aprendizaje profundo para la clasificación de imágenes de la columna vertebral, se ve necesario realizar el abordaje de cómo se lleva a cabo este proceso. El proceso de aprendizaje de transferencia inicia por medio de la obtención de cada uno de los modelos, como fue explorado en secciones anteriores cada uno de estos cuenta con su propia arquitectura, dividida en diversas capas. Cada uno de los modelos cuenta con una capa de salida la cual ya fue entrenada con los pesos obtenidos de ImageNet.

Sin embargo, debido a que esta capa de salida no se ajusta al problema de clasificación de este estudio, se ve necesario añadir capas personalizadas adicionales a los modelos, con sus propios parámetros para el desarrollo de la tarea de clasificación de imágenes de la columna vertebral. Dentro de las capas añadidas se encuentra una capa de normalización de lotes que cuenta como parámetro principal la variable momentum cuyo valor es de 0.99, esta variable está destinada a controlar como se lleva a cabo la normalización.

Otra de las capas personalizadas añadidas a los modelos pre-entrenados es la capa densa la cual cuenta con 256 unidades de salida y la función de activación ReLU. Adicionalmente se añade una capa de abandono, también conocida popularmente como Dropout, el parámetro establecido en esta capa es una tasa de abandono del 40%, lo que indica que, durante las iteraciones realizadas, el 40% de las unidades de los modelos pre-entrenados serán apagadas durante el entrenamiento. Por último, se añade la capa de salida que implementa el problema de clasificación para esta investigación, los parámetros en esta capa son la cantidad de clases (tres debido a que son las clases escoliosis, espondilolistesis y sin escoliosis) y la función de activación Softmax (Ilustración 19).



**Ilustración 19- Proceso de Aprendizaje de Transferencia**

Fuente: Elaboración Propia.

## 4.3.2 HERRAMIENTAS

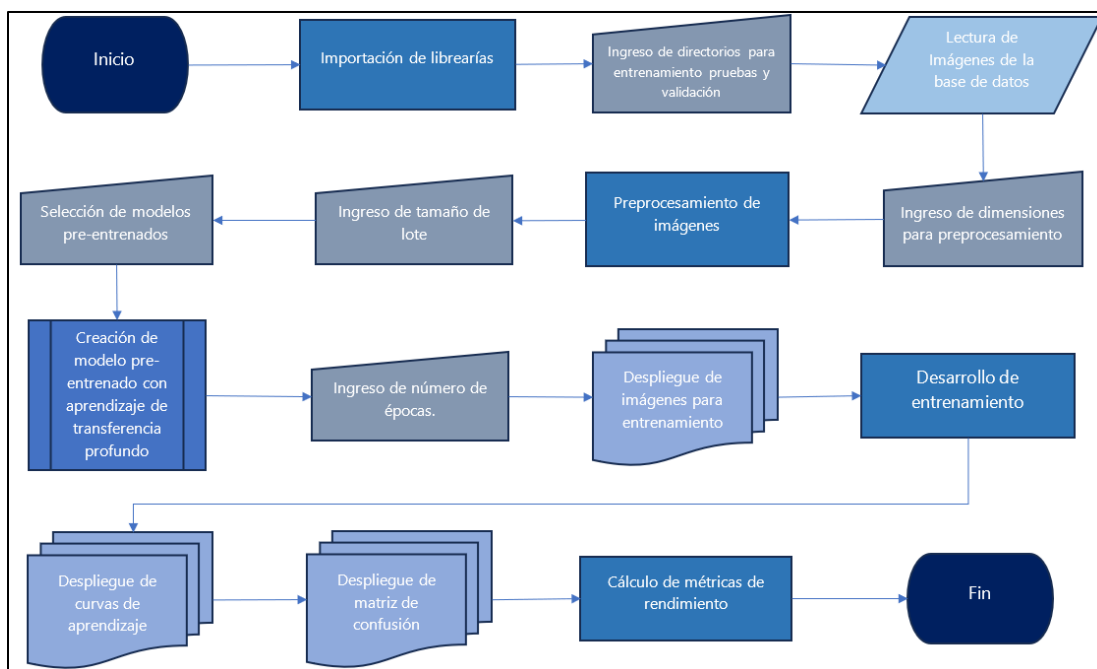
### 4.3.2.1 *Kaggle*

Dentro de las herramientas se tienen las plataformas que se utilizaron para entrenar, realizar pruebas y validar el algoritmo, siendo uno de estos Kaggle. Esta es una plataforma de aprendizaje automático e inteligencia artificial que tiene como objetivos brindar problemáticas de ciencia de datos, conjuntos de datos públicos y herramientas para que investigadores puedan colaborar, aprender y competir en proyectos de análisis y modelado de datos.

En Kaggle se obtuvo el algoritmo de clasificación de imágenes, así como también una de las bases de datos de imágenes de rayos X de la columna vertebral de pacientes que se utilizó. El código cuyo lenguaje de programación es Python incluye diversas funciones para la realización de las tareas de clasificación, además aplica librerías de procesamiento de imágenes dentro de las cuales se encuentran OpenCV, Matplotlib, OS, Numpy y Panda además de incorporar librerías de aprendizaje automático como Tensorflow y Albumentations.

El algoritmo fue desarrollado por un ingeniero del Sector Gubernamental de Motorola y General Dynamics y fue publicado el 20 de julio del 2023 (Piosenka, 2023). La Ilustración 20 muestra el diagrama de flujo del código que se utilizó para el desarrollo de un abordaje

de aprendizaje de transferencia profunda para la clasificación de escoliosis y espondilolistesis.



**Ilustración 20- Diagrama de flujo del código**

Fuente: Elaboración Propia.

#### 4.3.2.2 Roboflow

Por último, Roboflow es una plataforma para construir modelos de visión por computadora. Cuenta con un conjunto de herramientas para entrenar y mejorar modelos de visión artificial, como la detección de objetos, segmentación y reconocimiento facial Barayan et al. (2022). De esta plataforma se obtuvo una de las bases de datos de imágenes de rayos X.

## 4.4 MATERIALES

Los materiales de esta investigación fueron las bases de datos a utilizar que cuentan con imágenes de rayos X de la columna vertebral de pacientes que presentan deformidades vertebrales como escoliosis y espondilolistesis, así como pacientes sanos, es decir, que no tengan ninguna deformidad o patología en la columna vertebral.

Se utilizaron tres bases de datos, la primera fue obtenida de la plataforma Kaggle. Esta base de datos contiene imágenes de rayos X de la columna vertebral de pacientes que

visitaron el Hospital Universitario Rey Abdullah, Universidad de Ciencia y Tecnología de Jordania, Irbid, Jordania. El conjunto de datos contiene 338 pacientes siendo 240 mujeres y 98 hombres de 9 meses a 79 años. Las imágenes de rayos X de pacientes sanos fue de 71, siendo 40 mujeres y 31 hombres de 9 meses a 56 años. Las imágenes de pacientes con espondilolistesis fueron de 79 siendo 49 mujeres y 30 hombres de 15 a 79 años. Por último, los pacientes diagnosticados con escoliosis fueron 188, siendo 151 mujeres y 37 hombres de 5 a 35 años de edad (Fraiwan et al., 2022).



**Ilustración 22-  
Paciente con  
Escoliosis  
Imagen Kaggle**



**Ilustración 23-  
Paciente Sano  
Imagen Kaggle**



**Ilustración 21-  
Paciente con  
Espondilolistesis  
Imagen Kaggle**

Fuente: (Fraiwan et al., 2022)

La segunda base de datos se obtuvo de la plataforma Roboflow. Esta se encuentra compuesta por 1760 imágenes radiográficas pertenecientes a la clase escoliosis (ITU, 2023).

La tercera base de datos obtenida de Roboflow contiene un total de 816 imágenes radiográficas pertenecientes a la clase espondilolistesis (Logan, 2022). Se fusionaron la base de datos de Roboflow y Kaggle para poder tener una sola base de datos de imágenes de rayos X.

La cuarta base de datos fue creada con las imágenes médicas de la columna vertebral de pacientes hondureños proporcionadas por la Sociedad de Neurocirujanos de Honduras y tres hospitales de la zona nor-occidental del país.



**Ilustración 25-  
Paciente Sano  
Imagen  
Roboflow**

Fuente: (ITU, 2023)



**Ilustración 24-  
Paciente con  
Escoliosis Imagen  
Roboflow**



**Ilustración 26-  
Paciente con  
Espondilolistesis  
Imagen Roboflow**

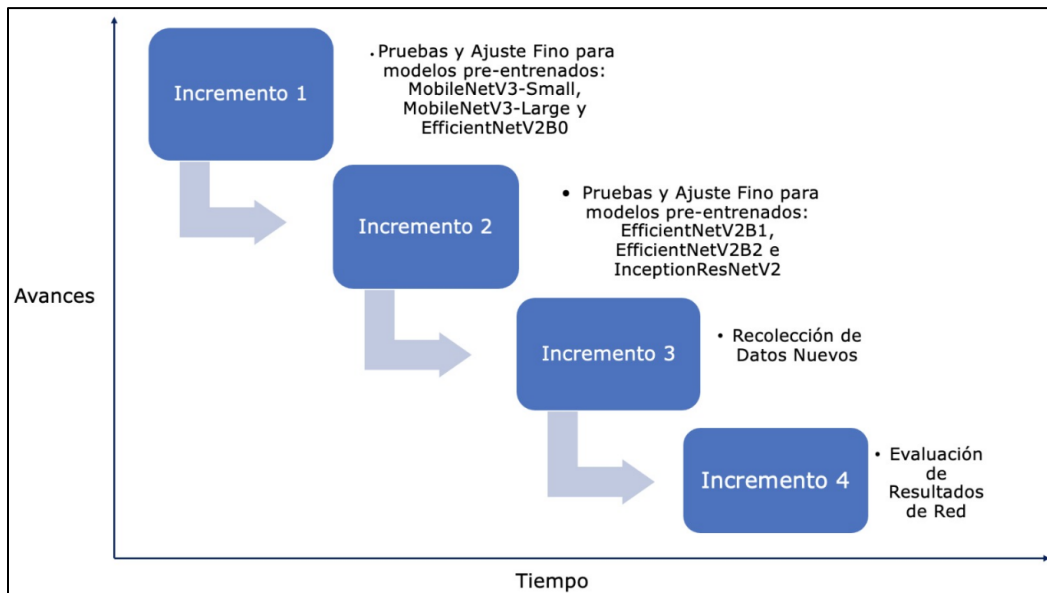
Fuente: (Logan, 2022)

## 4.5 METODOLOGÍA DE ESTUDIO

La metodología de estudio de la presente investigación consistió en la metodología incremental o iterativa. Esta metodología es esencial para el desarrollo de proyectos orientados al manejo de información. Esto debido a que los sistemas computacionales requieren de tres elementos fundamentales para su correcto desempeño; la entrada, el procesamiento y la salida. La metodología incremental o iterativa, empieza a partir de un bosquejo inicial y a medida el proceso avanza se desarrollan incrementos cada vez más complejos para entregar versiones más complejas del sistema.

La metodología incremental o iterativa consiste en diversas etapas conocidas como incrementos, permitiendo que el proceso de trabajo sea ordenado. Al llevar a cabo un proceso organizado se permite entregar un componente de trabajo distinto en cada incremento. Cada iteración se encarga de brindar un incremento funcional al desarrollo del elemento final (Bautista-Hernandez et al., 2022).

Para el desarrollo de la investigación, las tareas a realizar fueron divididas en un total de cuatro incrementos, cada incremento representa un mayor nivel de complejidad en el proceso a desarrollar (Ilustración 27).



**Ilustración 27- Esquema de Metodología Incremental o Iterativa.**

Fuente: Elaboración Propia.

## **4.6 METODOLOGÍA DE VALIDACIÓN**

La metodología de validación permite reconocer las bases científicas que soportan a la investigación, para este estudio se contempló la creación de un conjunto de datos de validación y el uso de herramientas gráficas como la matriz de confusión.

### **4.6.1 CREACIÓN DE CONJUNTO DE DATOS DE PRUEBA Y VALIDACIÓN**

Para la validez del estudio, se entabló la creación de conjuntos de prueba de las imágenes pertenecientes a las diferentes bases de datos que se utilizaron en las distintas etapas de la investigación, este conjunto surge a partir de la división del conjunto de entrenamiento, donde se destina una cierta cantidad de imágenes para validar el algoritmo. El conjunto de prueba para la clasificación de imágenes de la columna vertebral tiene como fin primordial evaluar el rendimiento de cada uno de los modelos de aprendizaje profundo utilizados recordando que son: MobileNetV3-Small, MobileNetV3-Large, EfficientNetV2B0, EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2.

De esta manera se logró ajustar los parámetros para el desarrollo de entrenamientos del algoritmo. El uso del conjunto de prueba permitió asegurar que los modelos no solo memorizaran los datos de entrenamiento, sino que estos generalizaran de manera correcta datos no vistos antes. En los incrementos destinados al entrenamiento del algoritmo se estableció que los modelos se exponen repetidamente al conjunto de datos de entrenamiento para posteriormente ajustar los diferentes parámetros como las épocas y el tamaño de lote para mejorar el rendimiento del algoritmo. Sin embargo, debido a que el objetivo final del modelo no se basa solamente en realizar predicciones en el conjunto de datos de entrenamiento, sino en clasificar nuevos datos, se ve necesario la implementación de un conjunto de datos de validación en los modelos que mejor se desempeñaron a lo largo de las pruebas ejecutadas en los distintos incrementos.

Por esta razón se propuso la creación de un conjunto de datos de validación a partir de las imágenes que fueron recolectadas localmente en colaboración con tres hospitales de la zona nor-occidental del país, así mismo se colaboró con la Sociedad Hondureña de Neurocirujanos con el mismo fin de recolectar datos y validar los modelos con imágenes que no se hayan utilizado durante el entrenamiento.

La eficiencia del algoritmo es evaluada por medio del rendimiento obtenido de la clasificación realizada en el conjunto de datos de validación. Los resultados de la validación fueron fundamentales para el estudio debido a que a partir de estos se lograron realizar predicciones reales una vez que los modelos seleccionados fueron entrenados. Las predicciones en el entorno del aprendizaje profundo consisten en la salida o resultado que un algoritmo genera en función de los datos de entrada.

4.6.2 MATRIZ DE CONFUSIÓN

La cuantificación de los datos de prueba se realizó por medio de un instrumento conocido como matriz de confusión, esta herramienta muestra la cantidad de aciertos y errores cometidos por el algoritmo para cada una de las clases contempladas en la salida. La matriz de confusión permite la obtención de cuatro posibles resultados conocidos como: Verdaderos Positivos (TP), Falsos Positivos (FP), Verdaderos Negativos (TN) y Falsos Negativos (FN). Una vez cuantificados los resultados obtenidos del conjunto de prueba se pueden calcular las métricas de rendimiento del algoritmo. La matriz de confusión permite reconocer si el algoritmo en cuestión presenta problemas de sesgo hacia alguna de las clases establecidas además muestra la existencia de dificultades que se pueden presentar en la clasificación (Ilustración 28).

		Matriz de Confusión		
		Clase #1	Clase #2	Clase #3
Actual	Clase #1	7	2	3
	Clase #2	0	14	2
	Clase #3	1	2	8
		Clase #1	Clase #2	Clase #3
		Predicción		

**Ilustración 28- Ejemplo de Matriz de Confusión.**

Fuente: Elaboración Propia.

### 4.6.3 ANÁLISIS Y CÁLCULOS NÚMERICOS

Al momento de la recolección de los datos obtenidos de las diferentes etapas de entrenamiento establecidas, para la obtención de resultados fidedignos de la investigación y el desarrollo de conclusiones, se realizaron los debidos cálculos de las métricas contempladas para conocer el rendimiento del algoritmo al momento de ser sometido a diferentes parámetros y bases de datos utilizadas.

Las métricas calculadas fueron las siguientes:

#### 4.6.3.1 *Exactitud*

Según Abdullah et al. (2018), la exactitud se define como el porcentaje de resultados verdaderos de las muestras de prueba. La exactitud indica si el algoritmo está prediciendo correctamente las imágenes en todas las clases, tanto los valores positivos como los negativos. La exactitud del algoritmo de aprendizaje profundo (Ecuación 4) se calculó a partir de la siguiente ecuación:

$$Exactitud = \frac{\sum_i^{\text{Número de clases}} TP}{\text{Número de imágenes de prueba}} \times 100\%$$

#### **Ecuación 4- Exactitud para algoritmo de clasificación de imágenes**

Fuente: (Abdullah et al., 2018a)

Donde TP representa el número total de Verdaderos Positivos. Se logra definir a la exactitud como la razón de las predicciones correctas entre el número total de muestras de prueba.

#### 4.6.3.2 *Precisión*

Según Fraiwan et al. (2022) la precisión se comprende como la razón de los TP y todas las imágenes identificadas como positivas. La tarea de la precisión es medir que tan preciso es el algoritmo en la clasificación de las muestras que predice como positivas. La precisión del algoritmo de aprendizaje profundo (Ecuación 5) se calculó a partir de los datos obtenidos en la matriz de confusión mediante la siguiente ecuación:

$$Precisión = \frac{TP}{TP + FP} \times 100\%$$

#### **Ecuación 5- Precisión para algoritmo de clasificación de imágenes**

Fuente: (Fraivan et al., 2022)

Donde FP corresponde el número total de Falsos Positivos.

#### 4.6.3.3 *Sensibilidad*

Según Bautista-Hernandez et al. (2022), la sensibilidad es la medida del número total de objetos que han sido correctamente detectados. Esta métrica describe que tan sensible es el algoritmo para detectar todas las muestras que pertenecen a la clase positiva. La sensibilidad del algoritmo de aprendizaje profundo (Ecuación 6) se calculó a partir de la siguiente ecuación:

$$Sensibilidad = \frac{TP}{TP + FN} \times 100\%$$

#### **Ecuación 6- Sensibilidad de algoritmo de clasificación de imágenes**

Fuente: (Bautista-Hernández et al., 2022)

Donde FN corresponde el número total de Falsos Negativos.

#### 4.6.3.4 *Puntaje F1*

Según Fraiwan et al. (2022), el puntaje F1 es la media armónica de la precisión y la sensibilidad, de esta manera se proporciona una medida equilibrada del rendimiento del algoritmo para la clasificación de las imágenes pertenecientes al conjunto de datos propuestos. El puntaje F1 del algoritmo de aprendizaje profundo (Ecuación 7) se calculó a partir de la siguiente ecuación:

$$Puntaje F1 = 2 \times \frac{Sensibilidad \times Precisión}{Sensibilidad + Precisión} \times 100\%$$

#### **Ecuación 7- Puntaje F1 de algoritmo de clasificación de imágenes**

Fuente: (Fraivan et al., 2022)

#### 4.7 CRONOGRAMA DE ACTIVIDADES

A continuación, se muestra de manera cronológica cada una de las actividades a realizar a lo largo del periodo de julio a septiembre del 2023 (10 semanas) con sus respectivas fechas.

Semanas	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6	Semana 7	Semana 8	Semana 9	Semana 10
Búsqueda de base de datos	■	■	■							
Compilación de código		■	■	■						
Selección de modelo pre-entrenados			■	■	■					
Realización del incremento 1				■	■	■	■			
Realización del incremento 2					■	■	■	■		
Reunión con Neurocirujanos							■	■	■	
Visita al Hospital #1								■	■	■
Visita al Hospital #2 y #3									■	■

**Ilustración 29- Cronograma de Actividades Primer Parcial**

Fuente: Elaboración Propia.

#### 4.8 MATRIZ METODOLÓGICA

A continuación, se visualizan algunas de las secciones esenciales de dicha investigación como el título, el problema, preguntas y objetivos de la investigación. Además, se enumeran las variables dependientes e independientes, así como las técnicas y herramientas a utilizar para poder llevarla a cabo.

**Tabla 10- Matriz Metodológica**

Título	Problema de Investigación	Preguntas de Investigación	Objetivos	Variables	Metodologías y Herramientas
<b>Algoritmos de Clasificación de Escoliosis y Espondilolistesis en Radiografías de Pacientes Hondureños</b>	En Honduras, actualmente no se cuenta con herramientas tecnológicas basadas en inteligencia artificial como lo son los algoritmos de clasificación para el apoyo en el proceso de diagnóstico de patologías como la escoliosis y espondilolistesis. Los	<b>General</b> ¿Cómo se pueden aumentar las métricas de desempeño de un algoritmo de clasificación de radiografías de escoliosis y espondilolistesis para su aplicación en imágenes radiográficas de la columna vertebral	<b>General</b> Aumentar las métricas de desempeño de un algoritmo de clasificación de radiografías de escoliosis y espondilolistesis.	<b>Dependientes</b> <input type="checkbox"/> Precisión <input type="checkbox"/> Sensibilidad <input type="checkbox"/> Puntaje F1 <input type="checkbox"/> Exactitud	<b>Técnicas</b> <input type="checkbox"/> MobileNetV3-small <input type="checkbox"/> MobileNetV3-large <input type="checkbox"/> EfficientNetV2B0 <input type="checkbox"/> EfficientNetV2B1 <input type="checkbox"/> EfficientNetV2B2 <input type="checkbox"/> InceptionResNetV2

<b>Título</b>	<b>Problema de Investigación</b>	<b>Preguntas de Investigación</b>	<b>Objetivos</b>	<b>Variables</b>	<b>Metodologías y Herramientas</b>
	<p>algoritmos de clasificación encargan de extraer características de las imágenes que son objeto de estudio y en base a los resultados obtenidos, se pueden organizar en diferentes clases permitiendo la optimización en el proceso de detección de estas deformidades de la columna vertebral. La implementación de un algoritmo</p>	<p>de de pacientes hondureños?</p> <p><b>Específicas</b></p>	<p><b>Específicos</b></p>	<p><b>Independientes</b></p>	<p><b>Herramientas</b></p>

Título	Problema de Investigación	Preguntas de Investigación	Objetivos	Variables	Metodologías y Herramientas
<p>involucra el cumplimiento de diversos parámetros como ser la exactitud que debe ser alta en esta aplicación. Además, esta es una línea de investigación poco explorada, evitando que se cuente con bases de datos propias de imágenes médicas pertenecientes a pacientes hondureños con estas desviaciones, para el desarrollo de fases de validación de un algoritmo de</p>	<p>1. ¿Qué parámetros se deben de modificar del modelo existente basados en la literatura para mejorar la precisión del algoritmo?</p> <p>2. ¿Son funcionales los modelos del estado del arte en imágenes de rayos X de pacientes hondureños?</p> <p>3. ¿Cómo se puede crear una base de datos con</p>	<p>1. Modificar parámetros de los modelos existentes basados en la literatura para intentar mejorar la precisión del algoritmo.</p> <p>2. Utilizar imágenes de rayos X de pacientes hondureños proporcionadas por la Sociedad de Neurocirujanos de Honduras, y tres hospitales de la zona nor-occidental del país, para</p>	<ul style="list-style-type: none"> <li><input type="checkbox"/> Modelos pre-entrenados de aprendizaje profundo</li> <li><input type="checkbox"/> Épocas</li> <li><input type="checkbox"/> Tamaño de Lote</li> <li><input type="checkbox"/> Tiempo de entrenamiento</li> </ul>	<ul style="list-style-type: none"> <li><input type="checkbox"/> Kaggle</li> <li><input type="checkbox"/> Roboflow</li> </ul>	

<b>Título</b>	<b>Problema de Investigación</b>	<b>Preguntas de Investigación</b>	<b>Objetivos</b>	<b>Variables</b>	<b>Metodologías y Herramientas</b>
	clasificación de las imágenes radiográficas de la columna vertebral.	de las imágenes recolectadas?	evaluar la aplicabilidad del algoritmo en imágenes utilizadas en el país. 3. Crear una base de datos con las imágenes recolectadas.		

Fuente: Elaboración Propia

#### 4.9 OPERACIONALIZACIÓN DE VARIABLES

A continuación, se presenta la tabla de las variables a estudiar en dicha investigación para exponer como se midieron y manipularon. Esto, con el fin de asegurar que las variables sean cuantificables y obtener datos confiables.

**Tabla 11- Operacionalización de Variables**

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
<b>Precisión</b>	Verdaderos Positivos	Son los eventos en los que el resultado es positivo y el modelo la clasifica correctamente como positivo.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
	Falsos Positivos	Son los eventos en los que el modelo clasifica de manera errónea ejemplos negativos como si fueran positivos.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
<b>Sensibilidad</b>	Verdaderos Positivos	Son los eventos en los que el resultado es positivo y el modelo la clasifica	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
		correctamente como positivo.				
	Falsos Negativos	Son los eventos en los que el modelo clasifica incorrectamente ejemplos positivos como negativos.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
<b>Puntaje F1</b>	Precisión	La proporción de elementos que el sistema devuelve y que son exactamente correctos.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
	Sensibilidad	La medición total de todos los objetos que fueron detectados de manera correcta.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
<b>Exactitud</b>	Sumatoria de los Verdaderos Positivos de cada Clase	La suma (+) de todos los verdaderos positivos para todas las clases.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
	Número de Imágenes para Pruebas	Cantidad total de imágenes que se tienen en la fase de validación del algoritmo.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
<b>Modelos pre-entrenados de aprendizaje profundo</b>	Tamaño de Entrada	Tamaño de las imágenes de entrada para que el modelo pueda procesarlos correctamente.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Tamaño de Salida	Tamaño de las imágenes de salida para que el modelo pueda procesarlos correctamente.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Pesos	Son factores que un modelo usa para aprender y representar las relaciones entre las variables de entrada y las salidas deseadas	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
		durante la fase de entrenamiento.				
	Pooling	Proceso usado para reducir el tamaño de las representaciones generadas por las capas convolucionales.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	Alta Mediana Baja
<b>Épocas</b>	Número de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana 3. Baja

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
<b>Tamaño de Lote</b>	Número de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana 3. Baja
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana 3. Baja
	Naturaleza de los Datos	Características de las imágenes.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana 3. Baja
<b>Tiempo de entrenamiento</b>	Número total de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana

<b>Variables</b>	<b>Dimensiones</b>	<b>Definición Operacional</b>	<b>Tipo de Variable</b>	<b>Escala de Medición</b>	<b>Instrumento</b>	<b>Indicador de Calificación</b>
						3. Baja
	Hiperparámetros	Son las épocas y el tamaño de lote.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	1. Alta 2. Mediana 3. Baja

Fuente: Elaboración Propia

## V. RESULTADOS Y ANÁLISIS

El siguiente capítulo muestra los resultados obtenidos en cada uno de los incrementos planteados, tomando en cuenta las tareas especificadas en cada etapa. Los resultados se presentan en base a las métricas obtenidas por cada uno de los modelos en las diferentes pruebas realizadas, específicamente se contemplan las métricas de exactitud, precisión, sensibilidad y puntaje F1, además de los ponderados de cada una de estas.


### 5.1 INCREMENTO 1: PRUEBAS Y AJUSTE FINO PARA MODELOS PRE-ENTRENADOS: MOBILENETV3-SMALL, MOBILENETV3-LARGE Y EFFICIENTNETV2B0

El primer incremento se dividió en dos tareas principales, siendo la primera la composición de una base de datos para probar al algoritmo propuesto en la plataforma Kaggle. El total de imágenes del conjunto de datos fue de 2,914, sin embargo, mientras se realizó una revisión exhaustiva de los datos, las radiografías provenientes de las bases de datos compuestas por ITU (2023) y Logan (2022), requerían de una limpieza debido a que algunas de las imágenes presentes en las clases seleccionadas no eran pertenecientes a las mismas, haciendo que fuera necesario del descarte de estas imágenes. Por consecuencia, la base de datos para el desarrollo del entrenamiento del algoritmo de clasificación constó de un total de 665 imágenes, repartidas entre las tres clases conocidas. De esta manera la clase de escoliosis quedó con un total de 281 imágenes, la clase de espondilolistesis con un total de 245 y por último la clase de columna vertebral sin escoliosis con un total de 139 imágenes. Además, se destinó en este primer incremento al desarrollo de pruebas de tres modelos pre-entrenados de aprendizaje profundo, dentro de los cuales se encontraron; MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0.

Para el desarrollo de las pruebas, se consideró una división de los datos en tres conjuntos, siendo un 80% de la base de datos para la creación del conjunto de entrenamiento, 10% para el conjunto de pruebas y 10% para el conjunto de validación. Las pruebas fueron realizadas en el compilador proporcionado por la plataforma Kaggle. Durante las pruebas se destinó alcanzar un ajuste fino para cada uno de los modelos, este proceso consistió en entrenar al algoritmo para aprender los detalles y características

específicas de la tarea objetivo por medio de la manipulación de las variables independientes descritas anteriormente. Adicionalmente, los modelos evaluados en este incremento se ajustó el tamaño de las imágenes a las dimensiones [224,224,3], ya que son los valores de entrada para estas redes en específico.

Los parámetros establecidos para el desarrollo del entrenamiento fueron tres experimentos con épocas de 50, 75 y 100, además de realizar tres pruebas tomando tamaños de lotes de 20, 50 y 70, con un ritmo de aprendizaje predeterminado de 0.001. Al definir estos parámetros de manera incremental se espera observar gradualmente el rendimiento en la clasificación de imágenes de la columna vertebral en las tres diferentes clases proporcionadas. A continuación, se presenta una muestra de cómo se observan las imágenes antes del procesado (Ilustración 30).



**Ilustración 30- Muestra de imágenes para entrenamiento del clasificador de imágenes.**

Fuente: Elaboración Propia

Los resultados obtenidos en el Incremento 1 constan de tres tablas pertenecientes a las configuraciones establecidas en el algoritmo para el desarrollo de la tarea de clasificación de los diferentes modelos pre-entrenados utilizados en el estudio. El desenlace de los cálculos obtenidos fue a partir de los pesos de la última época entrenada. Se registró el tiempo de entrenamiento en segundos, y a partir de la matriz de confusión generada se

calcularon las métricas de desempeño como son la exactitud, precisión, sensibilidad y puntaje F1, para cada clase del conjunto de pruebas al momento de realizar la clasificación.

Además, dentro de los resultados se contemplan, el promedio de los porcentajes alcanzados para cada una de las métricas considerando las tres clases. Así mismo, se calcula el promedio ponderado el cual es fundamental para el análisis debido a que este es calculado a partir del número de imágenes para cada clase, tomando en consideración que la base de datos con la que se trabajó no se encuentra balanceada.

**Tabla 12- Comparativa de MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0 con un entrenamiento de 50 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)			
Época 50	20	Escoliosis	345.07	100.00	96.43	98.18			
		Espondilolistesis		96.15	100.00	98.04			
		Sin escoliosis		92.86	92.86	92.86			
		Exactitud				<b>97.01</b>			
		Promedio macro		96.34	96.43	96.36			
		Promedio Ponderado		97.07	97.01	97.02			
		50		Escoliosis	392.27	96.55	100.00	0.9825	
	Espondilolistesis		96.15	100.00		98.04			
	Sin escoliosis		100.00	85.71		92.31			
	Exactitud					<b>97.01</b>			
	Promedio macro		97.57	95.24		96.2			
	Promedio Ponderado		97.12	97.01		96.93			
	70		Escoliosis	392.11		100.00	89.29	94.34	
		Espondilolistesis	96.15		100.00	98.04			
		Sin escoliosis	81.25		92.86	86.67			
		Exactitud				<b>94.03</b>			
		Promedio macro	92.47		94.05	93.02			
		MobileNetV3-Small							

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	
MobileNetV3 - Large		Promedio Ponderado		94.65	94.03	94.12	
		Escoliosis	469.35	93.33	100.00	96.55	
	20	Espondilolostesis		96.15	100.00	98.04	
		Sin escoliosis		100.00	78.57	88.00	
		Exactitud				<b>95.52</b>	
		Promedio macro		96.50	92.86	94.20	
		Promedio Ponderado		95.78	95.52	95.32	
		Escoliosis	416.42	82.35	100.00	90.32	
	50	Espondilolostesis		100.00	96.00	97.96	
		Sin escoliosis		100.00	64.29	78.26	
		Exactitud				<b>91.04</b>	
		Promedio macro		94.12	86.76	88.85	
		Promedio Ponderado		92.63	91.04	90.65	
		Escoliosis	404.64	82.35	100.00	90.32	
	70	Espondilolostesis		96.00	96.00	96.00	
		Sin escoliosis		87.50	50.00	63.64	
		Exactitud				<b>88.06</b>	
		Promedio macro		88.62	82.00	83.32	
		Promedio Ponderado		88.52	88.06	86.86	
		Escoliosis	412.09	100.00	100.00	100.00	
	EfficientNetV2B0	20	Espondilolostesis		96.15	100.00	98.04
			Sin escoliosis		100.00	92.86	96.30
			Exactitud				<b>98.51</b>
			Promedio macro		98.72	97.62	98.11
Promedio Ponderado				98.56	98.51	98.49	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
	50	Escoliosis	575.85	100.00	100.00	100.00
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	92.86	96.30
		Exactitud				<b>98.51</b>
		Promedio macro		98.72	97.62	98.11
		Promedio Ponderado		98.56	98.51	98.49
		Escoliosis		440.88	100.00	96.43
	Espondilolistesis	96.15	100.00		98.04	
	Sin escoliosis	92.86	92.86		92.86	
	Exactitud				<b>97.01</b>	
	Promedio macro	96.34	96.43		96.36	
	Promedio Ponderado	97.07	97.01		97.02	

Fuente: Elaboración Propia

Debido a los resultados obtenidos se puede observar que los modelos pre-entrenados estudiados en este incremento realizan de manera óptima la tarea de clasificación propuesta. El valor subrayado indica la exactitud alcanzada en cada prueba. Una vez realizado el primer experimento se designa un aumento de épocas de 50 a 75 para analizar el comportamiento de los modelos al momento de desarrollar un entrenamiento con un número de épocas más alto, los resultados del experimento con un número de épocas de 75 se pueden observar en la Tabla 13.

**Tabla 13- Comparativa de modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0 con un entrenamiento de 75 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	
Época 75	MobileNetV3-Small	20	436.93	Escoliosis	100.00	96.43	98.18
		Espondilolistesis		92.59	100.00	96.15	
		Sin escoliosis		92.31	85.71	88.89	
		Exactitud				<b>95.52</b>	
		Promedio macro		94.97	94.05	94.41	
		Promedio Ponderado		95.63	95.52	95.48	
		50		548.12	Escoliosis	96.55	100.00
	Espondilolistesis	96.15	100.00		98.04		
	Sin escoliosis	100.00	85.71		92.31		
	Exactitud				<b>97.01</b>		
	Promedio macro	97.57	95.24		96.2		
	Promedio Ponderado	97.12	97.01		96.93		
	70	553.01	Escoliosis		96.55	100.00	98.25
	Espondilolistesis		96.15	100.00	98.04		
	Sin escoliosis		100.00	85.71	92.31		
	Exactitud				<b>97.01</b>		
	Promedio macro		97.57	95.24	96.20		
	Promedio Ponderado		97.12	97.01	96.93		
	MobileNetV3-Large		20	754.65	Escoliosis	93.33	100.00
	Espondilolistesis	92.59	100.00		96.15		
	Sin escoliosis	100.00	71.43		83.33		
Exactitud			<b>94.03</b>				
Promedio macro	95.31	90.84	92.01				
Promedio Ponderado	94.45	94.03	93.64				

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)		
EfficientNetV2-B0	50	Escoliosis	674.96	90.32	100.00	94.92		
		Espondilolistesis		96.15	100.00	98.04		
		Sin escoliosis		100.00	71.43	83.33		
		Exactitud				<b>94.03</b>		
		Promedio macro		95.49	90.48	92.10		
		Promedio Ponderado		94.52	94.03	93.66		
	70	Escoliosis	590.09	90.32	100.00	94.92		
		Espondilolistesis		96.00	96.00	96.00		
		Sin escoliosis		90.91	71.43	80.00		
		Exactitud				<b>92.54</b>		
		Promedio macro		92.41	89.14	90.31		
		Promedio Ponderado		92.56	92.54	92.20		
	20	Escoliosis	650.83	100.00	100.00	100.00		
		Espondilolistesis		96.15	100.00	98.04		
		Sin escoliosis		100.00	92.86	96.30		
		Exactitud				<b>98.51</b>		
		Promedio macro		98.72	97.62	98.11		
		Promedio Ponderado		98.56	98.51	98.49		
		50		Escoliosis	727.79	100.00	100.00	100.00
				Espondilolistesis		96.15	100.00	98.04
				Sin escoliosis		100.00	92.86	96.30
				Exactitud				<b>98.51</b>
				Promedio macro		98.72	97.62	98.11
				Promedio Ponderado		98.56	98.51	98.49
70	Escoliosis	825.09	100.00	96.43	98.18			
	Espondilolistesis		96.15	100.00	98.04			

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
		Sin escoliosis		92.86	92.86	92.86
		Exactitud				<b>97.01</b>
		Promedio macro		96.34	96.43	96.36
		Promedio Ponderado		97.07	97.01	97.02

Fuente: Elaboración Propia

Los resultados obtenidos muestran que los modelos pre-entrenados estudiados en este experimento nuevamente desempeñan de manera eficaz la clasificación de imágenes de la columna vertebral. El valor destacado en cada prueba indica la exactitud alcanzada. Después de completar este segundo experimento, se aumentó el número de épocas de 75 a 100 para investigar cómo se comportan los modelos cuando se entrenan durante un período más largo. Los resultados del experimento con 100 épocas se encuentran en la Tabla 14.

**Tabla 14-Comparativa de modelos MobileNetV3-Small, MobileNetV3-Large y EfficientNetB0 con un entrenamiento de 100 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 100	MobileNetV3-Small	Escoliosis	586.20	100.00	92.86	96.30
		Espondilolistesis		92.59	100.00	96.15
		Sin escoliosis		92.86	92.86	92.86
		Exactitud				<b>95.52</b>
		Promedio macro		95.15	95.24	95.10
		Promedio Ponderado		95.74	95.52	95.52
		Escoliosis		799.36	100.00	96.43
	Espondilolistesis	96.15	100.00		98.04	
	Sin escoliosis	92.86	92.86		92.86	
	Exactitud				<b>97.01</b>	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
MobileNetV3-Large		Promedio macro		96.34	96.43	96.36
		Promedio Ponderado		97.07	97.01	97.02
	70	Escoliosis	804.42	0.9333	100.00	0.9655
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	78.57	0.88
		Exactitud				<b>95.52</b>
		Promedio macro		96.5	92.86	94.2
		Promedio Ponderado		95.78	95.52	95.32
	20	Escoliosis	734.78	93.10	96.43	94.74
		Espondilolistesis		92.59	100.00	96.15
		Sin escoliosis		100.00	78.57	88.00
		Exactitud				<b>94.03</b>
		Promedio macro		95.23	91.67	92.96
		Promedio Ponderado		94.35	94.03	93.86
	50	Escoliosis	825.62	93.33	100.00	96.55
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	78.57	88.00
		Exactitud				<b>95.52</b>
		Promedio macro		96.50	92.86	94.20
		Promedio Ponderado		95.78	95.52	95.32
	70	Escoliosis	752.75	90.32	100.00	94.92
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	71.43	83.33

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
EfficientNetV2-B0		Exactitud				<b>94.03</b>
		Promedio macro		95.49	90.48	92.10
		Promedio Ponderado		94.52	94.03	93.66
	20	Escoliosis	839.49	100.00	100.00	100.00
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	97.62	96.30
		Exactitud				<b>98.51</b>
		Promedio macro		98.72	97.62	98.11
		Promedio Ponderado		98.56	98.51	98.49
	50	Escoliosis	970.23	100.00	96.43	98.18
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		92.86	92.86	92.86
		Exactitud				<b>97.01</b>
		Promedio macro		96.34	96.43	96.36
		Promedio Ponderado		97.07	97.01	97.02
	70	Escoliosis	902.23	100.00	100.00	100.00
		Espondilolistesis		96.15	100.00	98.04
		Sin escoliosis		100.00	92.86	96.30
		Exactitud				<b>98.51</b>
		Promedio macro		98.72	97.62	98.11
		Promedio Ponderado		98.56	98.51	98.49

Fuente: Elaboración Propia

Por último, se muestran los resultados de las pruebas realizadas en los entrenamientos de los modelos con 100 épocas. Se logra apreciar nuevamente, que el valor destacado es la

exactitud alcanzada con el conjunto de pruebas, y se demuestra que la tarea de clasificación se logra de manera eficiente.

El Incremento 1 estuvo compuesto con un total de 27 pruebas desarrolladas, entre los tres modelos y las nueve configuraciones establecidas. El fin de esta etapa fue comparar las redes neuronales convolucionales MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2-B0 con el desempeño de las variables dependientes para identificar con que configuración de parámetros se alcanzó la exactitud más alta. En resumen, para la red MobileNetV3-Small se obtuvo la exactitud y precisión más alta con un número de épocas de 50 y un tamaño de lote de 50.

El modelo MobileNetV3-Large alcanzó un mejor desempeño con una configuración de 50 épocas y un tamaño de lote de 20. Por último, la primera versión de la red EfficientNetV2B0 evaluada obtuvo un rendimiento óptimo en relación con el tiempo de entrenamiento y las métricas evaluadas en la configuración perteneciente a un número de 50 épocas y un tamaño de lote de 20.

## **5.2 INCREMENTO 2: PRUEBAS Y AJUSTE FINO PARA MODELOS PRE-ENTRENADOS: EFFICIENTNETV2B1, EFFICIENTNETV2B2 E INCEPTIONRESNETV2**

El segundo incremento consistió en el desarrollo de pruebas y ajuste fino a los tres siguientes modelos pre-entrenados de aprendizaje profundo; EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2. El entrenamiento del algoritmo se desarrolló con el mismo conjunto de datos, es decir 665 imágenes pertenecientes a las tres clases con las que cuenta la base de datos. Así mismo se tomó en cuenta la misma división de los datos que se realizó en el Incremento 1. Al igual que en el incremento anterior, el ajuste fino se logró por medio de la manipulación de las variables independientes, de modo que se pudieran obtener las métricas deseadas. De la misma manera los parámetros establecidos para el desarrollo del entrenamiento del algoritmo con estos modelos fueron experimentos con épocas de 50, 75 y 100, además de pruebas con tamaños de lotes de 20, 50 y 70 con un ritmo de aprendizaje predeterminado de 0.001.

Similar al Incremento 1, los resultados obtenidos en este nuevo incremento se conforman de tres tablas pertenecientes a las diferentes configuraciones de los parámetros

establecidos en el algoritmo, para la realización de la tarea de clasificación. Para el desarrollo de comparativas entre los modelos estudiados, nuevamente se establece como contenido de las tablas de resultados, el tiempo de entrenamiento determinado en segundos, y cada una de las métricas calculadas en los reportes de clasificación generados por cada prueba realizada, adicionando el cálculo del promedio general y ponderado de cada una de las métricas obtenidas.

Para el Incremento 2, se evaluaron los modelos EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2. Para los primeros dos modelos se ajustó el tamaño de las imágenes a las dimensiones [224,224,3] y para el modelo de InceptionResNetV2 se realizó un ajuste con las dimensiones [299,299,3], ya que estos son los valores para los datos de entrada en las redes respectivas. Los resultados obtenidos para el primer experimento desarrollado con 50 épocas se muestran en la Tabla 15.

**Tabla 15- Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 50 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 50	20	Escoliosis	445.33	96.55	100	98.25
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	85.71	92.31
		Exactitud		<b>97.01</b>		
		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93
		Escoliosis		450	96.55	100
	Espondilolistesis	96.15	100		98.04	
	Sin escoliosis	100	85.71		92.31	
	Exactitud	<b>97.01</b>				
	Promedio macro	97.57	95.24		96.2	
	Promedio Ponderado	97.12	97.01		96.93	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
EfficientNetV2-B2	70	Promedio Ponderado		97.12	97.01	96.93
		Escoliosis	479.75	96.55	100	98.25
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	85.71	92.31
		Exactitud				<b>97.01</b>
		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93
	20	Escoliosis	535.09	96.43	96.43	96.43
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		92.31	85.71	88.89
		Exactitud				<b>95.52</b>
		Promedio macro		94.96	94.05	94.45
		Promedio Ponderado		95.46	95.52	95.45
		50	Escoliosis	982.77	100	100
	Espondilolistesis			96.15	100	98.04
	Sin escoliosis			100	92.86	96.3
	Exactitud					<b>98.51</b>
	Promedio macro			98.72	97.62	98.11
	Promedio Ponderado			98.56	98.51	98.49
	70		Escoliosis	889.77	96.55	100
		Espondilolistesis		96.15	100	98.04
Sin escoliosis			100	85.71	92.31	
Exactitud					<b>97.01</b>	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
InceptionResNet-V2		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93
	20	Escoliosis	535.09	100	100	100
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	92.86	96.3
		Exactitud				<b>98.51</b>
		Promedio macro		98.71	97.62	98.11
		Promedio Ponderado		98.56	98.51	98.49
	50	Escoliosis	982.77	96.55	100	98.25
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	85.71	92.31
		Exactitud				<b>97.01</b>
		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93
	70	Escoliosis	889.77	100	96.43	98.18
		Espondilolistesis		92.59	100	96.15
		Sin escoliosis		100	92.86	96.3
		Exactitud				<b>97.01</b>
		Promedio macro		97.53	96.43	96.88
		Promedio Ponderado		97.24	97.01	97.03

Fuente: Elaboración Propia

De acuerdo con los porcentajes de las métricas obtenidas se puede concluir que cada modelo en el Incremento 2 demostró un rendimiento destacado en la tarea de clasificación propuesta, cuando se considera un entrenamiento de 50 épocas. Seguidamente, se procedió

a realizar el aumento del número de épocas de 50 a 75 para analizar el efecto de una nueva configuración de los parámetros del algoritmo en las métricas de rendimiento en los reportes de clasificación. Los resultados para el segundo experimento con un número de épocas de 75 se muestran en la Tabla 16.

**Tabla 16- Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 75 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	
Época 75	EfficientNetV2-B1	20	Escoliosis	677.82	96.55	100	98.25
			Espondiloliste sis		96.15	100	98.04
			Sin escoliosis		100	85.71	92.31
			Exactitud				<b>97.01</b>
			Promedio macro		97.57	95.24	96.2
			Promedio Ponderado		97.12	97.01	96.93
			Escoliosis		765.11	96.55	100
	Espondiloliste sis	96.15	100	98.04			
	Sin escoliosis	100	85.71	92.31			
	Exactitud			<b>97.01</b>			
	Promedio macro	97.57	95.24	96.2			
	Promedio Ponderado	97.12	97.01	96.93			
	Escoliosis	793.69	96.55	96.43		98.18	
	Espondiloliste sis		96.15	100	98.04		
	Sin escoliosis		100	92.86	92.86		
	Exactitud				<b>97.01</b>		
	Promedio macro		96.34	96.43	96.36		
	Promedio Ponderado		97.07	97.01	97.02		
	EfficientNetV2-B2		20	Escoliosis	1206.72	100	92.86
		Espondiloliste sis		89.29		100	94.34
		Sin escoliosis		92.31		85.71	88.89
Exactitud						<b>94.03</b>	

InceptionResNet-V2		Promedio macro		93.86	92.86	93.17	
		Promedio Ponderado		94.39	94.03	94.02	
	50	Escoliosis	710.2	100	100	100	
		Espondiloliste sis		96.15	100	98.04	
		Sin escoliosis		100	92.86	96.3	
		Exactitud				<b>98.51</b>	
		Promedio macro		98.72	97.62	98.11	
		Promedio Ponderado		98.56	98.51	98.49	
	70	Escoliosis	1376.39	100	96.43	98.18	
		Espondiloliste sis		100	100	100	
		Sin escoliosis		93.33	100	96.55	
		Exactitud				<b>98.51</b>	
		Promedio macro		97.78	98.81	98.24	
		Promedio Ponderado		98.61	98.51	98.52	
	20	Escoliosis	1361.5	100	96.43	98.18	
		Espondiloliste sis		92.59	100	96.15	
		Sin escoliosis		100	92.86	96.3	
		Exactitud				<b>97.01</b>	
		Promedio macro		97.53	96.43	96.88	
		Promedio Ponderado		97.24	97.01	97.03	
		50	Escoliosis	1412.92	100	100	100
			Espondiloliste sis		96.15	100	98.04
			Sin escoliosis		100	92.86	96.3
			Exactitud				<b>98.51</b>
Promedio macro				98.72	97.62	98.11	
Promedio Ponderado				98.56	98.51	98.49	
70	Escoliosis	1374.21	100	96.43	98.18		
	Espondiloliste sis		96.15	100	98.04		
	Sin escoliosis		92.86	92.86	92.86		

	Exactitud			<b>97.01</b>
	Promedio macro	96.34	96.43	96.36
	Promedio Ponderado	97.07	97.01	97.02

Fuente: Elaboración Propia

Una vez más, en este segundo experimento, se reafirma la observación de que las clasificaciones efectuadas en el conjunto de pruebas por los tres modelos pertenecientes al Incremento 2 han sido realizadas de manera óptima. Para completar el Incremento 2, se procedió a incrementar el número de épocas a 100. Los resultados derivados de las pruebas ejecutadas en este tercer y último experimento se ven reflejados en la Tabla 17.

**Tabla 17-Comparativa de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 con un entrenamiento de 100 épocas.**

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 100	20	Escoliosis	898.36	96.55	100	98.25
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	85.71	92.31
		Exactitud				<b>97.01</b>
		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93
		Escoliosis		928.76	100	96.43
	Espondilolistesis	96.15	100		98.04	
	Sin escoliosis	92.86	92.86		92.86	
	Exactitud				<b>97.01</b>	
	Promedio macro	96.34	96.43		96.36	
	Promedio Ponderado	97.07	97.01		97.02	
	Escoliosis	902.23	96.55		100	98.25
	Espondilolistesis		96.15	100	98.04	
	Sin escoliosis		100	85.71	92.31	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	
EfficientNetV2-B2		Exactitud				<b>97.01</b>	
		Promedio macro		97.57	95.24	96.2	
		Promedio Ponderado		97.12	97.01	96.93	
	20	Escoliosis	1201.66	96.55	100	98.25	
		Espondiloli stesis		96.15	100	98.04	
		Sin escoliosis		100	85.71	92.31	
		Exactitud				<b>97.01</b>	
		Promedio macro		97.57	95.24	96.2	
		Promedio Ponderado		97.12	97.01	96.93	
	50	Escoliosis	982.77	100	100	100	
		Espondiloli stesis		96.15	100	98.04	
		Sin escoliosis		100	92.86	96.3	
		Exactitud				<b>98.51</b>	
		Promedio macro		98.72	97.62	98.11	
		Promedio Ponderado		98.56	98.51	98.49	
	70	Escoliosis	889.77	96.55	100	98.25	
		Espondiloli stesis		96.15	100	98.04	
		Sin escoliosis		100	85.71	92.31	
		Exactitud				<b>97.01</b>	
		Promedio macro		97.57	95.24	96.2	
		Promedio Ponderado		97.12	97.01	96.93	
	InceptionResNet-V2	20	Escoliosis	2470.49	100	100	100
			Espondiloli stesis		96.15	100	98.04
			Sin escoliosis		100	92.86	96.3
Exactitud						<b>98.51</b>	

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
		Promedio macro		98.72	97.62	98.11
		Promedio Ponderado		98.56	98.51	98.49
	50	Escoliosis	1721.91	100	96.43	98.18
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		92.86	92.86	92.86
		Exactitud				<b>97.01</b>
		Promedio macro		96.34	96.43	96.36
		Promedio Ponderado		97.07	97.01	97.02
	70	Escoliosis	1709.88	96.55	100	98.25
		Espondilolistesis		96.15	100	98.04
		Sin escoliosis		100	85.71	92.31
		Exactitud				<b>97.01</b>
		Promedio macro		97.57	95.24	96.2
		Promedio Ponderado		97.12	97.01	96.93

Fuente: Elaboración Propia

Finalmente, se presentan los desenlaces de las evaluaciones llevadas a cabo en los procesos de entrenamiento de los modelos utilizando 100 épocas para entrenamiento. Es evidente, una vez más, que el valor resaltado corresponde a la exactitud lograda en las pruebas, demostrando que la tarea de clasificación se ejecuta de manera efectiva.

Esta segunda etapa incluyó un total de 27 pruebas realizadas, que involucraron a tres modelos de aprendizaje profundo diferentes a los del Incremento 1 y nueve configuraciones específicas. El propósito de esta fase fue analizar las redes neuronales convolucionales EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 en términos de su rendimiento en relación con la configuración de parámetros que lograra la mayor exactitud.

En resumen, se encontró que para la red EfficientNetV2B1, la exactitud y precisión más alta se alcanzaron con 50 épocas y un tamaño de lote de 20. En el caso de la tercera versión,

el modelo EfficientNetV2B2 su mejor desempeño se logró con 75 épocas y un tamaño de lote de 70. Finalmente, el modelo InceptionResNetV2 demostró un rendimiento óptimo en términos de las métricas evaluadas con la configuración de 50 épocas y un tamaño de lote de 20.

### **5.3 INCREMENTO 3: RECOLECCIÓN DE DATOS NUEVOS**

Seguidamente, en el tercer incremento se destacó la recolección de imágenes para la creación de una base de datos de radiografías de la columna vertebral de pacientes hondureños en las tres clases definidas con antelación; escoliosis, espondilolistesis y radiografías de columna vertebral sin escoliosis. Esto se logró por medio de la colaboración con el servicio de radiología de tres hospitales de la zona nor-occidental del país, adicionalmente se contó con la colaboración de la Sociedad de Neurocirujanos de Honduras. Es importante mencionar que los datos recopilados en el caso de las instituciones hospitalarias visitadas son imágenes radiográficas de periodo de julio a septiembre del año 2023.

Los datos recopilados en el primer hospital constan de radiografías de tipo dorsal posteroanterior, dorsolumbar posteroanterior, lumbosacra posteroanterior y lumbosacra lateral, el total de datos recopilados en la visita realizada a esta institución hospitalaria fue de 56 imágenes repartidas tanto en pacientes femeninos como masculinos.

Para el caso del segundo hospital, se cuenta con el mismo tipo de radiografías de la columna vertebral siendo compuesto el conjunto de datos por un total de 94 imágenes. Por último, en la visita realizada al tercer hospital se recopiló un total de 96 radiografías siendo únicamente radiografías dorsales posteroanterior, lumbosacra posteroanterior y lumbosacra lateral.

Los datos recopilados en colaboración con la Sociedad de Neurocirujanos de Honduras radican en un total de 1,007 imágenes de tres diferentes modalidades de imágenes que son la resonancia magnética (370), tomografía computarizada (520) y radiografías (117). Además, se resaltó que las imágenes recolectadas pertenecen a pacientes de diversas afecciones de la columna vertebral sobre todo la hernia discal, espondilolistesis,

escoliosis y fracturas. Las imágenes se recolectaron en diversas secciones de la columna como cervical, dorsolumbar y lumbosacra, en diferentes planos anatómicos.

El fin primordial de la recopilación de este conjunto de datos, fue la creación de una base de datos consolidada de imágenes del tipo neurorradiología de pacientes hondureños que sienten la base para demostrar la aplicabilidad que posee el algoritmo de clasificación en base a los modelos pre-entrenados que alcanzaron el mayor porcentaje de las métricas calculadas a partir de las diferentes configuraciones evaluadas en las etapas previas de la investigación. La selección de los modelos más exactos y precisos se llevó a cabo en la sección 5.5 de este capítulo Discusión de Resultados.

#### **5.4 INCREMENTO 4: EVALUACIÓN DE RESULTADOS DE RED**

La evaluación de la funcionalidad del algoritmo entorno a su aplicación para la clasificación de imágenes radiográficas de la columna vertebral de pacientes hondureños se realizó por medio de predicciones con los modelos que mejor se desempeñaron a lo largo de las pruebas ejecutadas. Esto se logró mediante la creación de un conjunto de datos para validación a partir de las imágenes recolectadas localmente.

Se destacó del incremento anterior que del conjunto de datos entre las instituciones hospitalarias visitadas se cuenta con un total de 1,253 imágenes, sin embargo, para propósitos de esta investigación no todas las imágenes recopiladas fueron de valor, esto debido a que los entrenamientos y pruebas realizados en el Incremento 1 y 2 fueron específicamente desarrollados con radiografías dorsolumbares en una proyección posteroanterior para el caso de las clases escoliosis y columna vertebral sin escoliosis y radiografías lumbosacras en un corte lateral para el caso de la clase espondilolistesis.

Por lo tanto, la gran mayoría de las imágenes recopiladas de pacientes hondureños considerando que son de otros cortes anatómicos como dorsales posteroanterior y lumbosacra posteroanterior no fueron utilizadas para el desarrollo del conjunto de validación de radiografías local. A partir de este filtro se identificaron las radiografías que poseían las proyecciones y deformidades objetivo de este estudio estableciendo un total de 82 imágenes para validar los modelos pre-entrenados EfficientNetV2B0 y EfficientNetV2B2.

El conjunto de validación de radiografías de pacientes hondureños se compone de 35 radiografías dorsolumbares posteroanterior que presentan escoliosis, 29 radiografías lumbosacra laterales que presentan espondilolistesis y 18 radiografías dorsolumbares posteroanterior pertenecientes a columnas vertebrales sin escoliosis.

A partir de los modelos pre-entrenados que mejor se desempeñaron en el Incremento 1 y 2, se decidió realizar predicciones con este conjunto de imágenes radiográficas pertenecientes a pacientes hondureños. Una vez entrenado el algoritmo con los modelos EfficientNetV2B0 y EfficientNetV2B1 con las configuraciones establecidas para cada uno, se ejecutaron las predicciones.

A continuación, se muestra un fragmento del algoritmo donde se llevó a cabo el desarrollo de predicciones, las siguientes líneas de código muestran la definición de la función `predictor_validación()`, que toma como argumentos el modelo previamente entrenado, el generador del conjunto de validación y los datos de las dimensiones de las imágenes que se designaron en el entrenamiento. Las líneas dos y tres de este fragmento obtuvieron la lista de clases en el generador del conjunto de validación y obtiene el número de clases que hay en total.

A partir de aquí la variable `preds` se utilizó para hacer predicciones en el conjunto de validación, por último, las líneas cinco y seis permitieron generar dos listas vacías en donde se almacenaron los datos de las predicciones.

```
1 def predictor_validacion(model, valid_gen, img_height, img_width):
2     classes = list(valid_gen.class_indices.keys())
3     class_count = len(classes)
4     preds = model.predict(valid_gen, verbose=1)
5     correct_predictions = []
6     incorrect_predictions = []
```

### Ilustración 31- Fragmento de código para predicción #1

Fuente: Elaboración Propia

Posteriormente, se definió un ciclo `for` en la línea 8 que itera sobre los pares de índices y las predicciones almacenadas en la variable `preds` donde `i` es el índice del ejemplo del conjunto de validación y `p` es el conjunto de probabilidades para ese ejemplo. Dentro del ciclo, las líneas nueve y diez calculan el índice de la clase predicha como la clase que posee

la probabilidad más alta en el conjunto de probabilidades. Además, se obtiene el índice de la clase real del ejemplo en el conjunto de validación. Por último, en las líneas doce y catorce, se verifica si la clase predicha coincide con la clase real del ejemplo. Si es así, se añade a la lista de predicciones correctas, en caso de no serlo se añade a la lista de predicciones incorrectas.

```
8 for i, p in enumerate(preds):
9     pred_index = np.argmax(p)
10    true_index = valid_gen.labels[i]
11
12    if pred_index == true_index:
13        correct_predictions.append((i, pred_index))
14    else:
15        incorrect_predictions.append((i, pred_index, true_index))
```

### Ilustración 32- Fragmento de código para predicción #2

Fuente: Elaboración Propia

Del fragmento de código generado a partir de la línea dieciocho se creó una lista de la información perteneciente a las predicciones correctas. Nuevamente se inicializó un ciclo for que itera sobre i y p recordando que son los índices de las imágenes de validación y el conjunto de probabilidades desarrollado. La línea veinte obtuvo la ruta de la imagen correspondiente en el conjunto de validación, seguidamente se cargó la imagen y se redimensiona a las dimensiones específicas para la entrada de datos en los modelos EfficientNetV2B0 y EfficientNetV2B2.

Por último, la línea veintidós, calcula la confianza de la predicción como la probabilidad de la clase predicha multiplicada por cien. Esto debido a que la variable preds es una matriz que contiene las predicciones del modelo para el conjunto de validación de radiografías de pacientes hondureños. Para finalizar por medio de la librería Matplotlib se muestra la imagen, la predicción de a que clase pertenece y el nivel de confianza otorgado por el algoritmo.

```

18 correct_preds_info = []
19 for i, pred_index in correct_predictions:
20     image_path = os.path.join(valid_gen.directory, valid_gen filenames[i])
21     image = load_img(image_path, target_size=(img_height, img_width))
22     confidence = preds[i][pred_index] * 100
23     correct_preds_info.append((classes[pred_index], confidence))
24     plt.figure(figsize=(6, 6))
25     plt.imshow(image)
26     plt.title(f'Predicción: {classes[pred_index]}\nConfianza:
{confidence:.2f}%')
27     plt.axis('off')
28     plt.show()

```

### Ilustración 33- Fragmento de código para predicción #3

Fuente: Elaboración Propia

## 5.5 DISCUSIÓN DE RESULTADOS

En esta sección del Capítulo V: Análisis y Resultados, se explorarán los hallazgos encontrados en las diferentes etapas desarrolladas en la investigación de modo que se pueda definir el significado de los resultados obtenidos y explorar el valor científico de los mismos. Esto por medio de una amplia interpretación de los datos y una comparación de estos con las metodologías expuestas en el Estado del Arte.

### 5.5.1 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 1

La tarea de clasificación en tres clases de la columna vertebral fue medida a través del desempeño logrado por los modelos pre-entrenados de aprendizaje profundo asignados en el Incremento 1. Las observaciones realizadas sobre esta fase se basan en el objetivo de evaluar la efectividad del algoritmo propuesto por medio de las pruebas desarrolladas. La Tabla 18 muestra la relación obtenida entre las variables dependientes e independientes en relación con la selección de las configuraciones que alcanzaron el mejor desempeño por cada modelo comprobado en esta etapa.


**Tabla 18- Configuración y métricas de desempeño alcanzadas en los modelos  
MobileNetV3-Small, MobileNetV3-Large y EfficientNetV2B0**

<b>Modelo</b>	<b>Época</b>	<b>Tamaño de lote</b>	<b>Tiempo (s)</b>	<b>Exactitud (%)</b>	<b>Precisión P. (%)</b>	<b>Sensibilidad P. (%)</b>	<b>Puntaje F1 P. (%)</b>
MobileNetV3-Small	50	50	392.27	97.01	97.12	97.01	96.93
MobileNetV3-Large	50	20	469.35	95.52	95.78	95.52	95.32
<b>EfficientNetV2B0</b>	<b>50</b>	<b>20</b>	<b>412.09</b>	<b>98.51</b>	<b>98.56</b>	<b>98.51</b>	<b>98.49</b>

Fuente: Elaboración Propia

Se contempla que para el Incremento 1, el modelo pre-entrenado de aprendizaje profundo que alcanzó el mayor porcentaje de las métricas evaluadas fue EfficientnetV2B0 con una exactitud de 98.51%, una precisión ponderada de 98.56%, sensibilidad ponderada de 98.51% y puntaje F1 ponderado de 98.49%. La métrica esencial en este estudio es la exactitud recordando que esta se obtiene a partir de la razón entre la suma del número total de elementos clasificados correctamente entre las tres clases designadas y el número total de elementos designados en el conjunto de pruebas que en este caso fueron un total de 67 imágenes repartidas entre las tres clases. Todo el entrenamiento constó de un 412.09 segundos equivalente a 6 minutos y 52.09 segundos siendo un valor relativamente corto para la cantidad de imágenes establecidas en el conjunto de entrenamiento.

Las métricas fueron obtenidas a partir de la herramienta definida anteriormente como matriz de confusión, la Ilustración 34 muestra la matriz de confusión para la prueba desarrollada con el modelo EfficientNetV2B0 con un número total de 50 épocas y un tamaño de lote de 20, recordando que es en la que se obtuvo el mejor desempeño en el Incremento 1. A continuación se muestra un ejemplo de cómo se lleva a cabo el proceso del cálculo de los indicadores de desempeño en el caso de la prueba realizada con EfficientNetV2B0 donde alcanzó el mejor rendimiento.



**Ilustración 34- Matriz de confusión de EfficientNetV2B0 con un entrenamiento de 50 épocas y un tamaño de lote de 20.**

Fuente: Elaboración Propia

Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo EfficientNetV2B0 únicamente se presentó un error donde se clasificó una imagen de la clase sin escoliosis como espondilolistesis. Los datos necesarios para el cálculo de las métricas de desempeño mostradas en la Tabla 18 se describen en la Tabla 19.

**Tabla 19- Matriz de Observación de EfficientNetV2B0 con un entrenamiento de 50 épocas y un tamaño de lote de 20.**

Clases	Mediciones			
	TP	TN	FP	FN
Escoliosis	28	39	0	0
Espondilolistesis	25	41	1	0
Sin escoliosis	13	53	0	1

Fuente: Elaboración Propia

A partir de la Ecuación 4 descrita en el capítulo anterior se obtuvo la exactitud general de clasificación:

$$\text{Exactitud General} = \frac{28 + 25 + 13}{67} \times 100\% = 98.51\%$$

Se empleó la Ecuación 5 para el cálculo de la precisión de cada clase de la siguiente manera:

$$\text{Precisión Clase Escoliosis} = \frac{28}{28 + 0} \times 100\% = 100\%$$

$$\text{Precisión Clase Espondilolistesis} = \frac{25}{25 + 1} \times 100\% = 96.15\%$$

$$\text{Precisión Clase Sin Escoliosis} = \frac{13}{13 + 0} \times 100\% = 100\%$$

Tomando en cuenta estos resultados se procedió a realizar el cálculo del promedio de la precisión general realizada por el clasificador y el promedio ponderado que toma en consideración el número de imágenes del conjunto de pruebas que se estableció por cada clase.

$$\text{Promedio de Precisión} = \frac{1 + 0.9615 + 1}{3} \times 100\% = 98.72\%$$

$$\text{Promedio Ponderado de Precisión} = \frac{1 \times (28) + 0.9615 \times (25) + 1 \times (14)}{67} \times 100\% = 98.56\%$$

Se utilizó la Ecuación 6 para el cálculo de la sensibilidad individual en cada clase de la siguiente manera:

$$\text{Sensibilidad Clase Escoliosis} = \frac{28}{28 + 0} \times 100\% = 100\%$$

$$\text{Sensibilidad Clase Espondilolistesis} = \frac{25}{25 + 0} \times 100\% = 100\%$$

$$\text{Sensibilidad Clase de Sin Escoliosis} = \frac{13}{13 + 1} \times 100\% = 92.86\%$$

A partir de los resultados anteriores se procedió a la obtención del promedio de la sensibilidad general alcanzada en la tarea de clasificación propuesta y el promedio ponderado de la sensibilidad tomando en cuenta el número de imágenes del conjunto de pruebas que se estableció en cada clase.

$$\text{Promedio de Sensibilidad} = \frac{1 + 1 + 0.9286}{3} \times 100\% = 97.62\%$$

$$\text{Promedio Ponderado de Sensibilidad} = \frac{1 \times (28) + 1 \times (25) + 0.9286 \times (14)}{67} \times 100\% = 98.51\%$$

Por último, se utilizó la Ecuación 7 para calcular el puntaje F1 para cada clase individual como se ejemplifica a continuación:

$$\text{Puntaje F1 Clase Escoliosis} = 2 \times \frac{1 \times 1}{1 + 1} \times 100\% = 100\%$$

$$\text{Puntaje F1 Clase Espondilolistesis} = 2 \times \frac{0.9615 \times 1}{0.9615 + 1} \times 100\% = 98.04\%$$

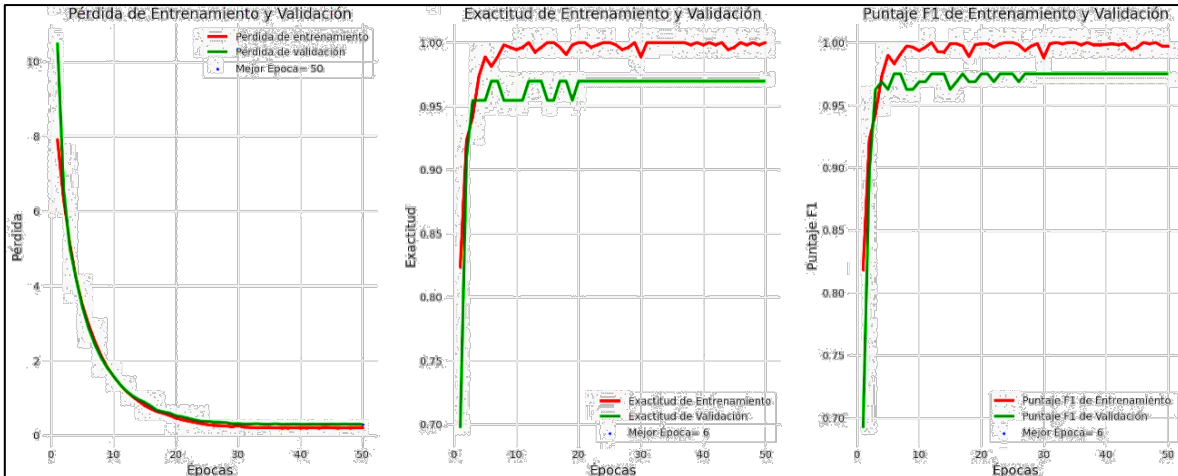
$$\text{Puntaje F1 Clase Sin Escoliosis} = 2 \times \frac{1 \times 0.9286}{1 + 0.9286} \times 100\% = 96.3\%$$

Finalmente, a partir de los resultados anteriores se consiguió calcular el promedio del puntaje F1 general alcanzado en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.

$$\text{Promedio de Puntaje F1} = \frac{1 + 0.9804 + 0.963}{3} \times 100\% = 98.11\%$$

$$\text{Promedio Ponderado de Puntaje F1} = \frac{1 \times (28) + 0.9804 \times (25) + 0.963 \times (14)}{67} \times 100\% = 98.49\%$$

Adicionalmente, se obtuvo el registro de las curvas de aprendizaje que incluyen la pérdida de entrenamiento y validación junto con las curvas de la exactitud y puntaje F1 de entrenamiento y validación (Ilustración 35).



**Ilustración 35- Curvas de aprendizaje de EfficientNetV2BO con 50 épocas y un tamaño de lote de 20.**

Fuente: Elaboración Propia

Una vez graficado la pérdida de entrenamiento junto con la pérdida de validación se logró destacar que el modelo presentó un comportamiento de aprendizaje estable, esto debido a que la pérdida de validación poseyó una respuesta similar a la pérdida de entrenamiento evitando el subajuste y sobreajuste del modelo. Por otro lado, las curvas de la exactitud de validación y puntaje F1 de validación por cada época entrenada, muestran que el modelo después de varias épocas logra ser constante en su aprendizaje, sin embargo, no alcanza la exactitud y puntaje F1 de entrenamiento indicando como en el caso de la investigación desarrollada por Fraiwan et al. (2022) que se ve la necesidad de aumentar el número de datos para el entrenamiento.

### 5.5.2 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 2

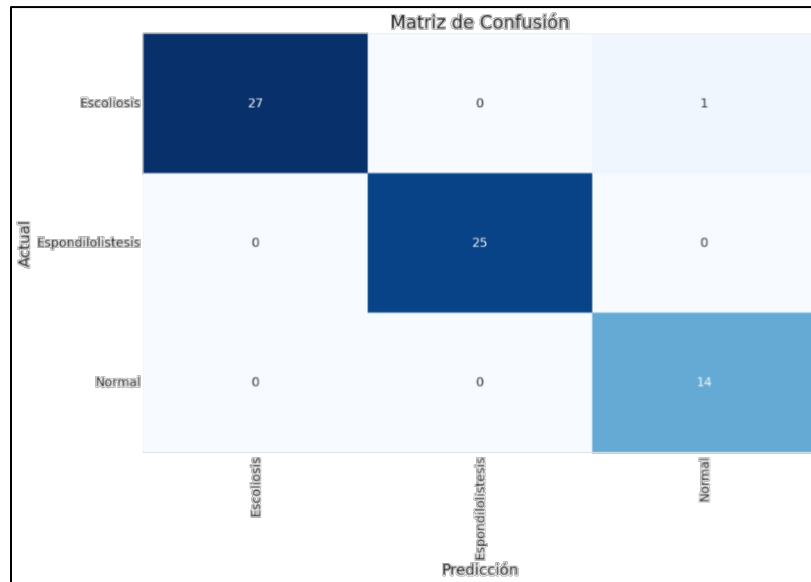
La evaluación del rendimiento se centró en los modelos de aprendizaje profundo pre-entrenados asignados en el Incremento 2, los cuales fueron utilizados para categorizar la columna vertebral en tres clases. En esta fase, se realizaron pruebas con el objetivo de medir el desempeño del algoritmo propuesto. La Tabla 20 presenta como las variables dependientes e independientes se relacionaron con la elección de las configuraciones que obtuvieron el rendimiento más destacado en cada uno de los modelos analizados en este proceso.

**Tabla 20- Configuración y métricas de desempeño alcanzadas en los modelos EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2.**

<b>Modelo</b>	<b>Época</b>	<b>Tamaño de lote</b>	<b>Tiempo (s)</b>	<b>Exactitud (%)</b>	<b>Precisión P. (%)</b>	<b>Sensibilidad P. (%)</b>	<b>Puntaje F1 P. (%)</b>
EfficientNetV2B1	50	20	445.33	97.01	97.12	97.01	96.93
<b>EfficientNetV2B2</b>	<b>75</b>	<b>70</b>	<b>1376.39</b>	<b>98.51</b>	<b>98.61</b>	<b>98.51</b>	<b>98.52</b>
InceptionResNetV2	50	20	904.41	98.51	98.56	98.51	98.49

Fuente: Elaboración Propia

En el marco del Incremento 2, se observó que tanto el modelo EfficientNetV2B2 como InceptionResNetV2, alcanzaron la misma exactitud con diferentes configuraciones, siendo esta de 98.51%, sin embargo, el modelo que obtuvo mejor desempeño en el resto de los indicadores calculados fue EfficientNetV2B2 alcanzando una precisión ponderada de 98.61%, sensibilidad ponderada de 98.51% y un puntaje F1 ponderado de 98.52%. Al igual que en la etapa anterior se constó de 67 imágenes en el conjunto de pruebas distribuidas en las tres clases. Vale la pena señalar que el tiempo de entrenamiento en el caso de InceptionResNetV2 fue menor, sin embargo, por una mínima diferencia EfficientNetV2B2 alcanzó un mejor desempeño.



**Ilustración 36- Matriz de Confusión de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño de lote de 70.**

Fuente: Elaboración Propia

Es evidente que, en la evaluación del conjunto de pruebas con esta configuración de parámetros en el modelo EfficientNetV2B2, se detectó un solo error en el desarrollo de la clasificación siendo este en la clase escoliosis donde una imagen fue clasificada en la clase sin escoliosis. Los detalles que se requieren para calcular las métricas de rendimiento que se mostraron en la Tabla 20, se describen a partir de la matriz de observación (Tabla 21).

**Tabla 21- Matriz de Observación de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño de lote de 70.**

Clases	Mediciones			
	TP	TN	FP	FN
Escoliosis	27	39	0	1
Espondilolistesis	25	42	0	0
Sin escoliosis	14	52	1	0

Fuente: Elaboración Propia

Nuevamente a partir de la Ecuación 4, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{27 + 25 + 14}{67} \times 100\% = 98.51\%$$

Se empleó la Ecuación 5 para el cálculo de la precisión de cada clase de la siguiente manera:

$$\textit{Precisión Clase Escoliosis} = \frac{27}{27 + 0} \times 100\% = 100\%$$

$$\textit{Precisión Clase Espondilolistesis} = \frac{25}{25 + 0} \times 100\% = 100\%$$

$$\textit{Precisión Clase Sin Escoliosis} = \frac{14}{14 + 1} \times 100\% = 93.33\%$$

Tomando en cuenta estos resultados se procedió a realizar el cálculo del promedio de la precisión general realizada por el clasificador y el promedio ponderado que toma en consideración el número de imágenes del conjunto de pruebas que se estableció por cada clase.

$$\textit{Promedio de Precisión} = \frac{1 + 1 + 0.9333}{3} \times 100\% = 97.78\%$$

$$\textit{Promedio Ponderado de Precisión} = \frac{1 \times (28) + 1 \times (25) + 0.9333 \times (14)}{67} \times 100\% = 98.61\%$$

Se utilizó la Ecuación 6 para el cálculo de la sensibilidad individual en cada clase de la siguiente manera:

$$\textit{Sensibilidad Clase Escoliosis} = \frac{27}{27 + 1} \times 100\% = 96.43\%$$

$$\textit{Sensibilidad Clase Espondilolistesis} = \frac{25}{25 + 0} \times 100\% = 100\%$$

$$\textit{Sensibilidad Clase Sin Escoliosis} = \frac{14}{14 + 0} \times 100\% = 100\%$$

A partir de los resultados anteriores se procedió a la obtención del promedio de la sensibilidad general alcanzada en la tarea de clasificación propuesta y el promedio ponderado de la sensibilidad tomando en cuenta el número de imágenes del conjunto de pruebas que se estableció en cada clase.

$$\textit{Promedio de Sensibilidad} = \frac{0.9643 + 1 + 1}{3} \times 100\% = 98.81\%$$

$$\text{Promedio Ponderado de Sensibilidad} = \frac{0.9643 \times (28) + 1 \times (25) + 1 \times (14)}{67} \times 100\% = 98.51\%$$

Por último, se utilizó la Ecuación 7 para calcular el puntaje F1 para cada clase individual como se ejemplifica a continuación:

$$\text{Puntaje F1 Clase Escoliosis} = 2 \times \frac{1 \times 0.9643}{1 + 0.9643} \times 100\% = 98.18\%$$

$$\text{Puntaje F1 Clase Espondilolistesis} = 2 \times \frac{1 \times 1}{1 + 1} \times 100\% = 100\%$$

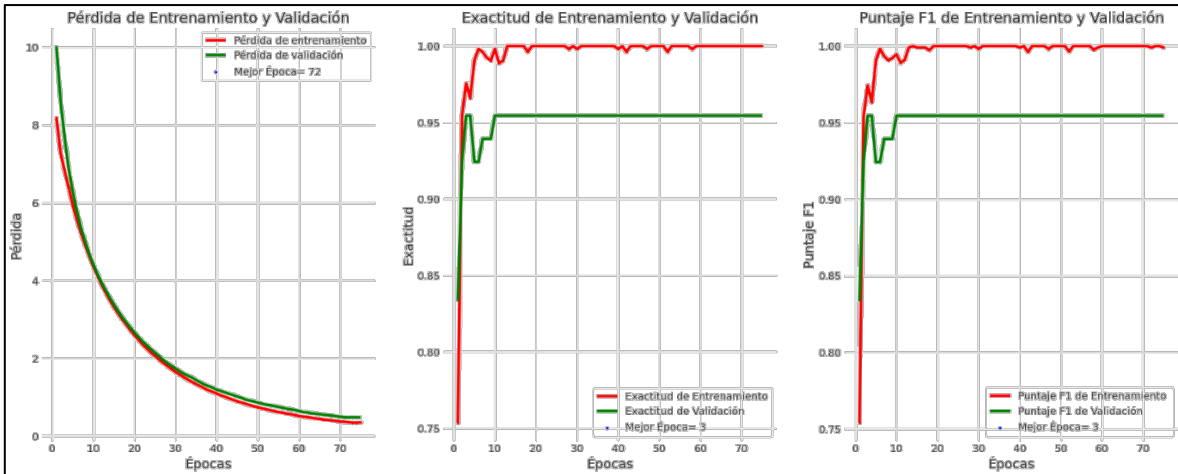
$$\text{Puntaje F1 Clase Sin Escoliosis} = 2 \times \frac{1 \times 0.9333}{1 + 0.9333} \times 100\% = 96.55\%$$

Finalmente, a partir de los resultados anteriores se consiguió calcular el promedio del puntaje F1 general alcanzado en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.

$$\text{Promedio de Puntaje F1} = \frac{0.9818 + 1 + 0.9655}{3} \times 100\% = 98.24\%$$

$$\text{Promedio Ponderado de Puntaje F1} = \frac{0.9818 \times (28) + 1 \times (25) + 0.9655 \times (14)}{67} \times 100\% = 98.52\%$$

Además, se registraron las curvas de aprendizaje, que contienen información sobre la pérdida durante el entrenamiento y la validación, así como las curvas de exactitud y puntaje F1 durante el entrenamiento y la validación (Ilustración 37).



**Ilustración 37-Curvas de aprendizaje de EfficientNetV2B2 con un entrenamiento de 75 épocas y un tamaño del lote de 70.**

Fuente: Elaboración Propia


Una vez que se representaron gráficamente las curvas de pérdida tanto para el entrenamiento como para la validación, se pudo observar que el modelo exhibió un patrón de aprendizaje estable. Esto se debió a que la curva de pérdida en la validación siguió una tendencia similar a la del entrenamiento, lo que indicó que el modelo evitaba tanto el subajuste como el sobreajuste.

Por otro lado, al observar las curvas de exactitud y puntaje F1 en la validación a lo largo de las épocas de entrenamiento, se notó que el modelo se comportaba de manera constante después de varias épocas. Sin embargo, al igual que en el Incremento 1, esta tercera versión del modelo EfficientNetV2, no logró alcanzar los niveles de exactitud y puntaje F1 que se vieron en el entrenamiento.

### 5.5.3 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 3

Los hallazgos derivados de las visitas realizadas en los tres establecimientos de salud para la recolección de radiografías de la columna vertebral muestran que, a lo largo de los meses de julio a septiembre del año 2023, se observó una cierta cantidad de pacientes que necesitaron exámenes de diagnóstico por imágenes para abordar problemas en la columna vertebral en sus diversas secciones. En el caso del primer hospital las imágenes recopiladas pertenecen a un total de 43 pacientes repartidos como 20 pacientes femeninos y 23

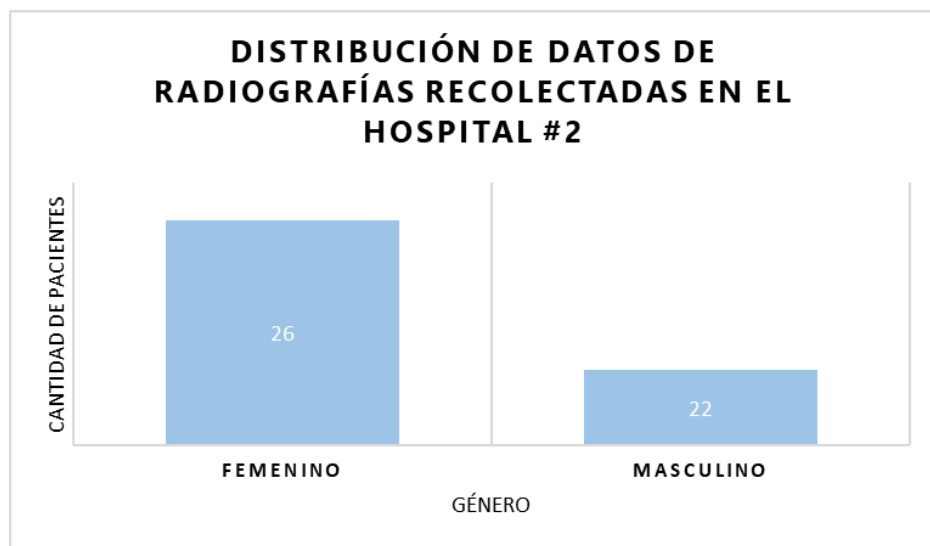
pacientes masculinos (Ilustración 38) Además, el rango de edad de los pacientes es de 3 a 74 años.



**Ilustración 38- Reparto de información de radiografías recolectadas en el primer hospital**

Fuente: Elaboración Propia


En el segundo hospital, se recolectaron radiografías de un total de 48 pacientes. De estos, 26 eran mujeres y 22 eran hombres (Ilustración 39). Los pacientes tenían edades que iban desde los 30 días hasta los 87 años.



**Ilustración 39- Reparto de datos de radiografías recolectadas en el segundo hospital**

Fuente: Elaboración Propia

Finalmente, la recopilación de información recabada en el tercer hospital indica que, durante el lapso de julio a septiembre, un grupo de 48 pacientes acudió a las instalaciones para someterse a una radiografía destinada a estudiar su columna vertebral. De este conjunto, 27 fueron mujeres y 21 hombres (Ilustración 40). La edad de los pacientes variaba entre los 19 y los 84 años.




**Ilustración 40- Reparto de datos de radiografías recolectadas en el tercer hospital.**

Fuente: Elaboración Propia

Estos datos son fundamentales para conocer las características demográficas de los pacientes a quienes pertenecen las radiografías de la columna vertebral que conforman a la nueva base de datos de pacientes hondureños.

#### 5.5.4 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 4

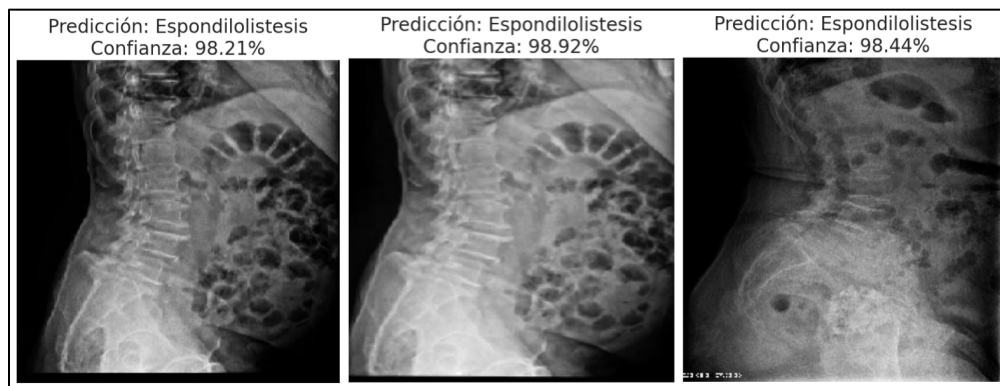
Para tanto el modelo EfficientNetV2B0 y EfficientNetV2B2 se realizaron un total de 82 predicciones en el conjunto de validación conformado por las imágenes radiográficas de los pacientes hondureños. Los resultados obtenidos en esta etapa final consisten en la salida que otorgan los modelos pre-entrenados seleccionados la cual es la identificación de a que clase pertenece la imagen en cuestión y cuál es el nivel de confianza otorgado. La Ilustración 41 muestra tres ejemplos de predicciones realizadas por EfficientNetV2B0 con imágenes que presentan escoliosis.



**Ilustración 41- Predicciones de escoliosis realizadas por EfficientNetV2B0**

Fuente: Elaboración Propia


La Ilustración 42 muestra el desarrollo de predicciones en radiografías laterales de pacientes con espondilolistesis hondureños.



**Ilustración 42- Predicciones de espondilolistesis realizadas por EfficientNetV2B0**

Fuente: Elaboración Propia

La Ilustración 43 muestra el desarrollo de predicciones en radiografías de pacientes con columna vertebral sin escoliosis de pacientes hondureños.

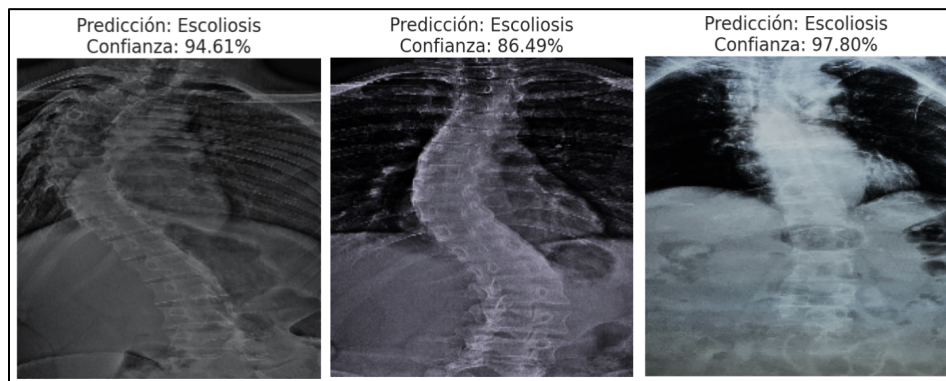


**Ilustración 43- Predicciones de columna vertebral sin escoliosis realizadas por EfficientNetV2B0**

Fuente: Elaboración Propia

Se destaca que a lo largo de las predicciones realizadas los niveles de confianza otorgados son bastante altos, sin embargo, a pesar de esto se obtuvieron un total de 24 errores en las predicciones realizadas al conjunto de validación. Representando una exactitud de 70.73% al momento de clasificar imágenes que el algoritmo jamás ha visto.

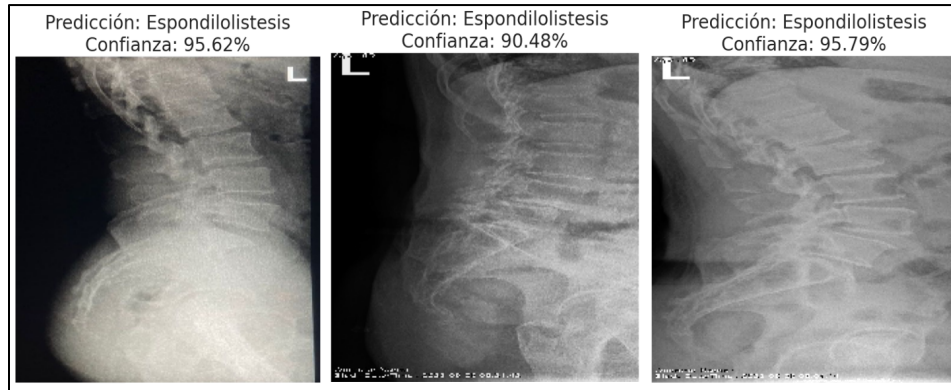
Finalmente se procedió a realizar las predicciones con el modelo EfficientNetV2B2. La Ilustración 44 muestra las predicciones realizadas con imágenes de pacientes hondureños que presentan escoliosis.



**Ilustración 44- Predicciones de escoliosis realizadas por EfficientNetV2B2**

Fuente: Elaboración Propia


La Ilustración 45 muestra las predicciones realizadas con imágenes de pacientes hondureños que presentan espondilolistesis.



**Ilustración 45- Predicciones de espondilolistesis realizadas por EfficientNetV2B2**

Fuente: Elaboración Propia

Se presentan las predicciones realizadas por EfficientNetV2B2 en imágenes de pacientes con columna vertebral sin escoliosis (Ilustración 46).



**Ilustración 46- Predicciones de columna vertebral sin escoliosis realizadas por EfficientNetV2B2**

Fuente: Elaboración Propia

A partir de las observaciones realizadas se destacó que las predicciones acertadas mantienen un porcentaje alto de confianza, sin embargo, EfficientNetV2B2 obtuvo un total de 25 errores de 82 imágenes predichas. Significando una exactitud de 69.51%. Concluyendo que al momento de clasificar datos nunca vistos el modelo pre-entrenado EfficientNetV2B0 resultó ser determinante en la tarea de clasificación propuesta.

Se demostró que gran cantidad de las imágenes fueron predichas correctamente, por lo tanto, se realizó una validación con la Sociedad de Neurocirujanos de Honduras para conocer si las predicciones realizadas corresponden a un pronóstico certero. Dentro de las observaciones claves se destaca que si bien la tarea de clasificación se realizó de manera

eficiente para optimizar el proceso de diagnóstico es necesaria la consideración de procesos de clasificación más robustos que permitan la categorización de las imágenes a base de identificación de datos biomecánicos como en el caso de la escoliosis, el cálculo del ángulo de Cobb, y en el caso de la espondilolistesis el porcentaje de desplazamiento de las vértebras lumbares.

#### 5.5.5 COMPARATIVA DE RESULTADOS OBTENIDOS CON LOS DEL ESTADO DEL ARTE

Como se mostró anteriormente en los resultados para el primer incremento, entre los diferentes modelos como MobileNetV3-small, MobileNetV3-large y EfficientNetV2B0 se alcanzó una exactitud de 97.01%. Por otro lado, para el segundo incremento, existe una exactitud con los modelos de EfficientNetV2B1, EfficientNetV2B2 e InceptionResNetV2 del 98.01%.

**Tabla 22- Resultados Obtenidos en las Metodologías descritas en el Estado del Arte**

Referencia	Número de Clases	Clasificador Utilizado	Método	Accuracy
<b>Ansari et al. (2013)</b>	4	MSV	Aprendizaje	87.29%
		RNA	Automático	89.36%
<b>Abdullah et al. (2018)</b>	2	KNN	Aprendizaje Automático	86.13%
<b>Imran et al. (2020)</b>	4	U-net	Aprendizaje Automático	97.8%
<b>Fraiwan et al. (2022)</b>	3	CNN	Aprendizaje profundo	96.34%
<b>Este trabajo</b>	3	CNN Incremento I	Aprendizaje	97.01%
		CNN Incremento II	profundo	98.01%

Fuente: Elaboración Propia

## VI. CONCLUSIONES

A lo largo de la investigación, se llevó a cabo una evaluación del aprendizaje de transferencia profunda con el propósito de asistir en el diagnóstico de deformidades de la columna vertebral, tales como la escoliosis y la espondilolistesis. Este enfoque se diseñó en respuesta al problema planteado. La metodología incluyó la ejecución de diversos ensayos utilizando seis modelos pre-entrenados que hacen uso de redes neuronales convolucionales como componente fundamental de su funcionamiento.

1. Con el resultado de las 54 pruebas desarrolladas en las diferentes fases de este estudio se logró optimizar las métricas de desempeño de un algoritmo de clasificación en tres clases pertenecientes a las radiografías de columna vertebral obtenidas. Se logró un promedio general entre los seis modelos evaluados de 97.51% en la exactitud calculada a lo largo de las diferentes pruebas desarrolladas. Tomando en cuenta que la exactitud fue considerada la métrica clave en la tarea de clasificación desarrollada por el algoritmo.
2. Se identificó a lo largo del estudio que los parámetros críticos que se necesitaban modificar para lograr un entrenamiento óptimo por parte de los modelos pre-entrenados estudiados eran el número de épocas y el tamaño de lote. En consecuencia, al modificar estos parámetros se observaron variaciones en las métricas de desempeño que incluyen la exactitud, precisión, sensibilidad y puntaje F1. Estas métricas fueron fundamentales para evaluar si los cambios en los parámetros del algoritmo permitían obtener un rendimiento adecuado en la tarea de clasificación propuesta.
3. Se utilizaron imágenes radiográficas de pacientes hondureños proporcionadas por la Sociedad de Neurocirujanos de Honduras, y tres hospitales de la zona norte del país, para evaluar la aplicabilidad que posee el algoritmo mediante predicciones en el conjunto de validación desarrollado a partir de las imágenes recolectadas y que pertenecían a las clases escoliosis, espondilolistesis y columna vertebral sin escoliosis, el modelo pre-entrenado EfficientNetV2B0 obtuvo menor número de errores siendo de 24 en un total de 82 predicciones.
4. A partir de las visitas desarrolladas a tres hospitales de la zona nor-occidental del país y a la Sociedad de Neurocirujanos de Honduras se creó una base de datos de imágenes

de la columna vertebral en diferentes modalidades como radiografías, resonancia magnética y tomografías computarizadas, que presentaron diversas patologías como escoliosis, espondilolistesis, hernia discal y fracturas. Que significó la apertura para nuevas avenidas de investigación en el procesamiento de imágenes médicas de pacientes hondureños.

## **VII. RECOMENDACIONES**

1. Evaluar otros modelos pre-entrenados para poder realizar una comparativa de diferentes redes neuronales convolucionales e identificar qué modelo cuenta con mayor precisión para la clasificación de imágenes radiográficas de la columna vertebral.
2. Probar los modelos pre-entrenados con bases de datos de imágenes radiográficas de la columna vertebral que estén balanceadas y considerar la aumentación de imágenes para futuras pruebas con el fin de entrenar y evaluar los modelos de manera más efectiva mejorando el rendimiento.
3. Las imágenes radiográficas de la columna vertebral que se deben de utilizar para que el algoritmo de clasificación las pueda categorizar correctamente deben de ser dorsolumbares en el caso de que la deformidad sea escoliosis y laterales en caso de ser espondilolistesis.
4. Implementar nuevas tareas de clasificación con el conjunto de bases de datos de las imágenes radiográficas de la columna vertebral para observar la factibilidad que posee el algoritmo en la resolución de nuevos problemas.

## **VIII. APLICABILIDAD/IMPLEMENTACIÓN**

1. El algoritmo de clasificación evaluado puede ser aplicado en futuros problemas de clasificación que involucren el aprendizaje de transferencia profunda. De esta manera se logrará ser de apoyo en el diagnóstico de deformidades de la columna vertebral al médico especialista, de esta manera contribuir con predicciones de las condiciones del paciente optimizando la automatización en la clasificación de imágenes médicas.
2. La creación de una base de datos local de imágenes médicas de pacientes hondureños es valiosa para futuras investigaciones que involucren el procesamiento de imágenes médicas. Esto puede impulsar a la colaboración entre instituciones de salud y académicas para avanzar en la comprensión y el diagnóstico de las condiciones de la columna vertebral en la población hondureña.

## **IX. TRABAJO FUTURO**

1. Realizar una interfaz gráfica de usuario y el prototipado amigable del clasificador de imágenes radiográficas para que sea utilizado para el diagnóstico de las deformidades de la columna vertebral como ser la escoliosis y la espondilolistesis por los neurocirujanos hondureños.
2. Investigar la disposición de los neurocirujanos hondureños en la implementación de dicho algoritmo de clasificación de imágenes de rayos X de la columna vertebral según la deformidad presente (escoliosis o espondilolistesis) para hacer más eficiente y rápido el proceso de diagnóstico de los pacientes hondureños que se atiendan.
3. Entrenar el algoritmo de clasificación de las imágenes radiográficas contenidas en la base de datos creada de los pacientes hondureños.

## REFERENCIAS BIBLIOGRÁFICAS

1. Abdullah, A. A., Yaakob, A., & Ibrahim, Z. (2018). Prediction of Spinal Abnormalities Using Machine Learning Techniques. *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, 1–6. <https://doi.org/10.1109/ICASSDA.2018.8477622>
2. Ansari, S., Sajjad, F., ul-Qayyum, Z., Naveed, N., & Shafi, I. (2013). Diagnosis of Vertebral Column Disorders Using Machine Learning Classifiers. *2013 International Conference on Information Science and Applications (ICISA)*, 1–6. <https://doi.org/10.1109/ICISA.2013.6579446>
3. Armenta, A. G. P., Martínez, E. E., Gonzalez, R. T., Garfias, A. R., & Prado, M. G. S. (2018). EPIDEMIOLOGICAL PANORAMA OF ORTHOPEDIC SPINE PATHOLOGY IN MEXICO. *Coluna/Columna*, 17, 120–123. <https://doi.org/10.1590/S1808-185120181702189430>
4. Barreras, M. T. (2011). *Escoliosis: Concepto, etiología y clasificación*. 7(2).
5. Bautista-Hernandez, G., Jimenez Nixon, D., & Reyes Duke, A. M. (2022). *Coral Reef Disease and Bleaching Identification through Computational Vision Algorithm*. 1–6. <https://doi.org/10.1109/CONESCAPAN56456.2022.9959584>
6. Burton, M. S. (2013). Diagnosis and Treatment of Adolescent Idiopathic Scoliosis. *Pediatric Annals*, 42(11). <https://doi.org/10.3928/00904481-20131022-09>

7. Bydon, M., Alvi, M. A., & Goyal, A. (2019). Degenerative Lumbar Spondylolisthesis. *Neurosurgery Clinics of North America*, 30(3), 299–304. <https://doi.org/10.1016/j.nec.2019.02.003>
8. Cifuentes, A., Mendoza, E., Lizcano, M., Santrich, A., & Moreno-Trillos, S. (2019). Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes. *Investigación y desarrollo en TIC*, 10(2), 7-17.
9. Cumbal Sánchez, Carlos Antonio. (2022). Análisis de imágenes de radiografías de la columna vertebral para calcular el ángulo de desviación en pacientes que padecen escoliosis utilizando técnicas de IA."Bachelor's thesis, 2022.
10. Derczynski, L. (2016). Complementarity, F-score, and NLP Evaluation. *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*, 261–266. <https://aclanthology.org/L16-1040>
11. Fraiwan, M., Audat, Z., Fraiwan, L., & Manasreh, T. (2022). Using deep transfer learning to detect scoliosis and spondylolisthesis from x-ray images. *PLOS ONE*, 17(5), e0267851. <https://doi.org/10.1371/journal.pone.0267851>
12. Freppel, S., Colnat-Coulbois, S., & Civit, T. (2009). Tratamiento quirúrgico de la espondilolistesis del adulto. *EMC - Técnicas Quirúrgicas - Ortopedia y Traumatología*, 1(1), 1–9. [https://doi.org/10.1016/S2211-033X\(09\)71615-9](https://doi.org/10.1016/S2211-033X(09)71615-9)
13. García, A. V. (2012). Fundamentos anatómicos de la columna vertebral en imágenes diagnósticas. Publicación Facultad de Medicina Departamento de Morfología Humana de la Universidad Nacional de Colombia. (Bogota DC. 2012:).

14. García-Ramos, C., Valenzuela-González, J., Baeza-Álvarez, V., Rosales-Olivarez, L., Alpizar-Aguirre, A., & Reyes-Sánchez, A. (2020). Espondilolistesis degenerativa lumbar I: Principios generales. *Acta Ortopédica Mexicana*, 34(5), 324–328. <https://doi.org/10.35366/97997>
15. Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). *Searching for MobileNetV3*. 1314–1324. [https://openaccess.thecvf.com/content\\_ICCV\\_2019/html/Howard\\_Searching\\_for\\_MobileNetV3\\_ICCV\\_2019\\_paper.html](https://openaccess.thecvf.com/content_ICCV_2019/html/Howard_Searching_for_MobileNetV3_ICCV_2019_paper.html)
16. Imran, A.-A.-Z., Huang, C., Tang, H., Fan, W., Cheung, K., To, M., Qian, Z., & Terzopoulos, D. (2020). Fully-Automated Analysis of Scoliosis from Spinal X-Ray Images. *2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*, 114–119. <https://doi.org/10.1109/CBMS49503.2020.00029>
17. Instituto Nacional de Estadística INE (2023). Estadísticas Médicas en Salud. Retrieved September 18, 2023, from <https://ine.gob.hn/v4/categoría-de-documentos/salud/>
18. ITU. (2023). crop-test Dataset [ Open Source Dataset ]. In Roboflow Universe . Roboflow . <https://universe.roboflow.com/itu-jewmd/crop-test-81m8p>
19. Janicki, J. A., & Alman, B. (2007). Scoliosis: Review of diagnosis and treatment. *Paediatrics & Child Health*, 12(9), 771–776. <https://doi.org/10.1093/pch/12.9.771>
20. Kalichman, L., & Hunter, D. J. (2008). Diagnosis and conservative management of degenerative lumbar spondylolisthesis. *European Spine Journal*, 17(3), 327–335. <https://doi.org/10.1007/s00586-007-0543-3>

21. Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
22. Logans Work Space. (2022). Spondylolisthesis Dataset [Open Source Dataset ]. In Roboflow Universe . Roboflow . %20<https://universe.roboflow.com/logans-work-space/spondylolisthesis%20>
23. Mahadevan, V. (2018). Anatomy of the vertebral column. *Surgery (Oxford)*, 36(7), 327–332. <https://doi.org/10.1016/j.mpsur.2018.05.006>
24. Mahajan, S., Raina, A., Gao, X.-Z., & Pandit, A. K. (2022). COVID-19 detection using hybrid deep learning model in chest x-rays images. *Concurrency and Computation: Practice and Experience*, 34(5), e6747. <https://doi.org/10.1002/cpe.6747>
25. Martínez & Pérez. (2018). PREVALENCIA DE ESPONDILOLISTESIS DEGENERATIVA EN PACIENTES FEMENINOS DE 50-70 AÑOS EN, CASA DEL ABUE, DIF SAN PEDRO CHOLULA, PUEBLA. Retrieved July 23, 2023, from [https://investigacion.upaep.mx/micrositios/reclu/assets/miep\\_prevalencia\\_de\\_espondilolistesis\\_degenerativa.pdf](https://investigacion.upaep.mx/micrositios/reclu/assets/miep_prevalencia_de_espondilolistesis_degenerativa.pdf)
26. Mohammed, B. (2022). *Applied Sciences | Free Full-Text | Effectiveness of Machine Learning in Assessing the Diagnostic Quality of Bitewing Radiographs*. <https://www.mdpi.com/2076-3417/12/19/9588>

27. Muñoz, A. B. F. (2011). *TRABAJO PRESENTADO AL CONSEJO DE LA FACULTAD DE HUMANIDADES*.
28. Ojeda, G. E. M. (2022). *DESARROLLO DE UN CLASIFICADOR BASADO EN REDES NEURONALES PARA LA DETECCIÓN DE ESCOLIOSIS EN IMAGEN RX DE COLUMNA. 2022*.
29. Organización Panamericana de la Salud. (2022). Perfil de País-Honduras. Salud en las Américas. <https://hia.paho.org/es/paises-2022/perfil-honduras>
30. Ortega, F. Z., Rodríguez, L. R., Morales, L. Z., Sánchez, M. F., & García, R. F. (2014). Análisis de la prevalencia de escoliosis y factores asociados en una población escolar mexicana mediante técnicas de cribado. *Gaceta Médica de México*.
31. Pantoja, T. S., & Chamorro, L. M. (2015). Escoliosis en niños y adolescentes. *Revista Médica Clínica Las Condes*, 26(1), 99–108. <https://doi.org/10.1016/j.rmcl.2015.02.011>
32. Pérez, N. V. R., Estrada, M. L., & Tovar, A. M. de A. (2018). Aplicación de Métodos de Inteligencia Artificial en el Área Médica. *Pistas Educativas*, 35(111), Article 111. <https://pistaseducativas.celaya.tecnm.mx/index.php/pistas/article/view/361>
33. Perrot-González, J. C., Adell-Serrano, B., Castañeda-Galeano, V. E., Gálvez-Koslowski, S., Santos-Andrés, F. J., & Aguilar Naranjo, J. J. (2013). Progresión en el adulto joven de la escoliosis idiopática tratada con ortesis. *Rehabilitación*, 47(3), 131–135. <https://doi.org/10.1016/j.rh.2013.03.001>


34. Piosenka (2023). General Image Classifier. Kaggle. Retrieved September 5, 2023, from <https://www.kaggle.com/code/gpiosenka/general-use-image-classifier-f1-scores-97-85#Define-a-function-to-plot-the-training-data>
35. Romero Rodríguez, C. V. (2019). Reconocimiento de imágenes para detección temprana de alteraciones posturales (Master's thesis, Universidad Técnica de Ambato. Facultad de Ingeniería en Sistemas, Electrónica e Industrial. Maestría en Automatización y Sistemas de Control).
36. Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), Article 1. <https://doi.org/10.1038/nmeth.3707>
37. Sampieri, H., Collado, F., & Lucio, B. (2014). *METODOLOGÍA DE LA INVESTIGACIÓN*.
38. Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y. (2017). Learning Pooling for Convolutional Neural Network. *Neurocomputing*, 224, 96–104. <https://doi.org/10.1016/j.neucom.2016.10.049>
39. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). *Going Deeper With Convolutions*. 1–9. [https://www.cv-foundation.org/openaccess/content\\_cvpr\\_2015/html/Szegedy\\_Going\\_Deeper\\_With\\_2015\\_CVPR\\_paper.html](https://www.cv-foundation.org/openaccess/content_cvpr_2015/html/Szegedy_Going_Deeper_With_2015_CVPR_paper.html)
40. Tan, M., & Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105–6114. <https://proceedings.mlr.press/v97/tan19a.html>

41. Universidad Científica del Sur, Facultad de Ciencias de la Salud, Carrera de Medicina Humana. Lima, Perú, Vázquez-Lazarte, A. S., Berta-Benites, C. A., Universidad Científica del Sur, Facultad de Ciencias de la Salud, Carrera de Medicina Humana. Lima, Perú, Runzer-Colmenares, F. M., & Universidad Científica del Sur, Facultad de Ciencias de la Salud, Carrera de Medicina Humana. Lima, Perú. (2020). Frecuencia de escoliosis idiopática del adolescente en alumnos de secundaria en seis colegios de Lima Norte. *Horizonte Médico (Lima)*, 20(4), e1172. <https://doi.org/10.24265/horizmed.2020.v20n4.05>
42. 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.*
43. Vázquez-Aguilar, A., Torres-Gómez, A., Atlitec-Castillo, P. T., León-Martínez, J. D., Vázquez-Aguilar, A., Torres-Gómez, A., Atlitec-Castillo, P. T., & León-Martínez, J. D. (2016). Espondilolistesis degenerativa. Influencia del índice de masa corporal en la evolución postquirúrgica. *Acta ortopédica mexicana*, 30(1), 13–16.
44. Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9(4), 611–629. <https://doi.org/10.1007/s13244-018-0639-9>
45. Yang, J., & Li, J. (2017). Application of deep convolution neural network. *2017 14th International Computer Conference on Wavelet Active Media Technology and*

*Information Processing (ICCWAMTIP), 229–232.*


<https://doi.org/10.1109/ICCWAMTIP.2017.8301485>

## ANEXOS




**Anexo 1- Matriz de Confusión MobileNetV3-Small, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 2- Gráficos de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




### Anexo 3- Matriz de Confusión MobileNet V3-Small, Época 50, Tamaño de Lote 50

Fuente: Elaboración Propia




### Anexo 4- Gráficas de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 50

Fuente: Elaboración Propia




**Anexo 5- Matriz de Confusión MobileNet V3-Small, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 6- Gráficas de Desempeño MobileNet V3-Small, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 7- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 8- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 9- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 10- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 11- Matriz de Confusión MobileNet V3-Small, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 12- Gráficas de Desempeño MobileNet V3-Small, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia



**Anexo 13- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote 20**


Fuente: Elaboración Propia



**Anexo 14- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote**


**20**

Fuente: Elaboración Propia



**Anexo 15- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote 50**


Fuente: Elaboración Propia



**Anexo 16- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote**


50

Fuente: Elaboración Propia



**Anexo 17- Matriz de Confusión MobileNet V3-Small, Época 100, Tamaño de Lote 70**


Fuente: Elaboración Propia



**Anexo 18- Gráficas de Desempeño MobileNet V3-Small, Época 100, Tamaño de Lote**


70

Fuente: Elaboración Propia




**Anexo 19- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 20- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 21- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 22- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 23- Matriz de Confusión MobileNet V3-Large, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 24- Gráficas de Desempeño MobileNet V3-Large, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 25- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 26- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 27- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 28- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 29- Matriz de Confusión MobileNet V3-Large, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 30- Gráficas de Desempeño MobileNet V3-Large, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia



**Anexo 31- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 20**


Fuente: Elaboración Propia



**Anexo 32- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote**


20

Fuente: Elaboración Propia



**Anexo 33- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 50**


Fuente: Elaboración Propia



**Anexo 34- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote**


50

Fuente: Elaboración Propia



**Anexo 35- Matriz de Confusión MobileNet V3-Large, Época 100, Tamaño de Lote 70**


Fuente: Elaboración Propia



**Anexo 36- Gráficas de Desempeño MobileNet V3-Large, Época 100, Tamaño de Lote**


70

Fuente: Elaboración Propia




**Anexo 37- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 38- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 39- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia



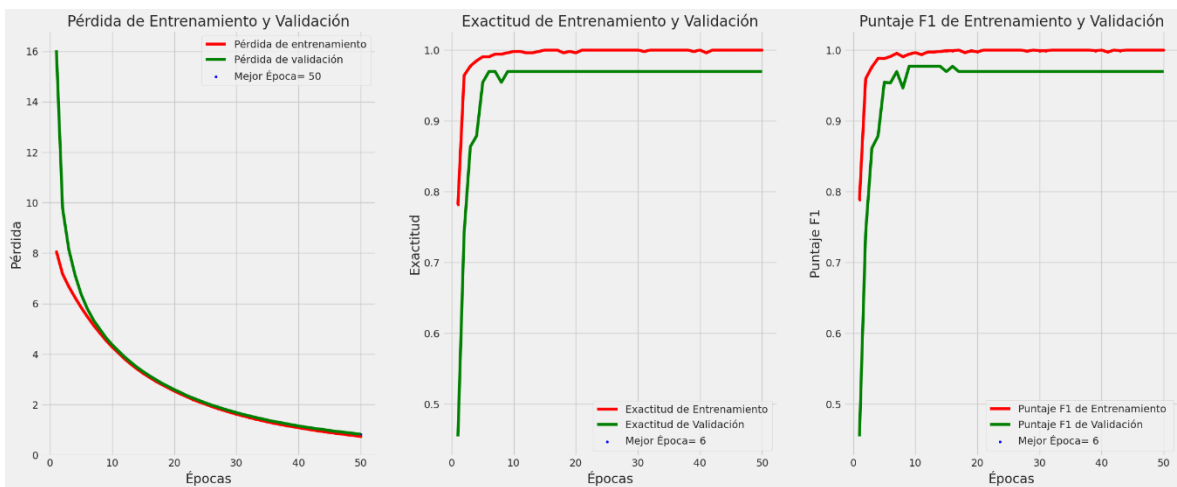
**Anexo 40- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 41- Matriz de Confusión EfficientNetV2B0, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 42- Gráficas de Desempeño EfficientNetV2B0, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 43- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 44- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 45- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 46- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 47- Matriz de Confusión EfficientNetV2B0, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 48- Gráficas de Desempeño EfficientNetV2B0, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 49- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 50- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 51- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 52- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 53- Matriz de Confusión EfficientNetV2B0, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 54- Gráficas de Desempeño EfficientNetV2B0, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 55- Matriz de Confusión EfficientNetV2B1, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 56- Gráficas de Desempeño EfficientNetV2B1, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 57- Matriz de Confusión EfficientNetV2B1, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 58- Gráficas de Desempeño EfficientNetV2B1, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 59- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 60- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 61- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 62- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 63- Matriz de Confusión EfficientNetV2B1, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia



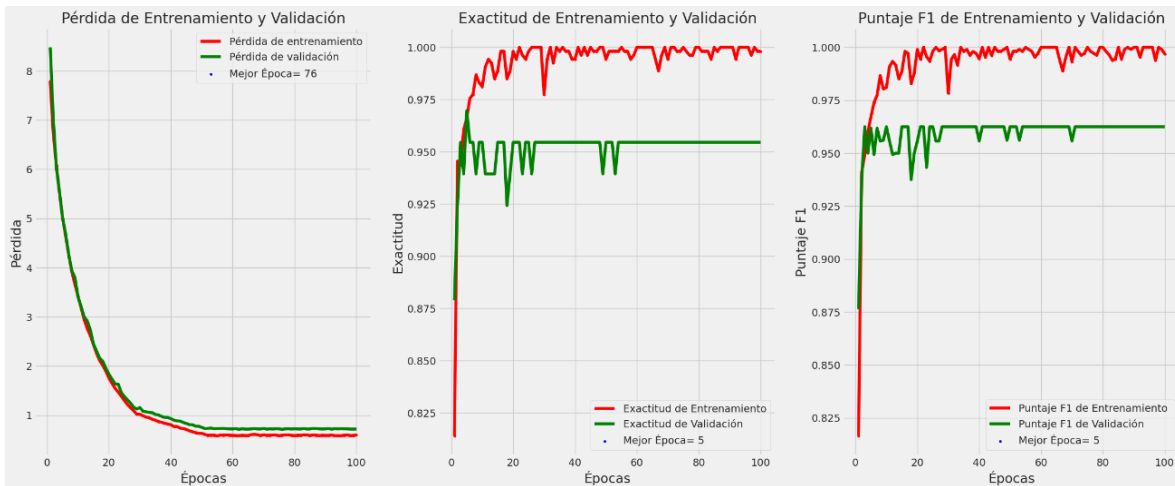
**Anexo 64- Gráficas de Desempeño EfficientNetV2B1, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 65- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 66- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 67- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 68- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 69- Matriz de Confusión EfficientNetV2B1, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 70- Gráficas de Desempeño EfficientNetV2B1, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 71- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 72- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 73- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 74- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 75- Matriz de Confusión EfficientNetV2B2, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 76- Gráficas de Desempeño EfficientNetV2B2, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 77- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 78- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 79- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 80- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 81- Matriz de Confusión EfficientNetV2B2, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia



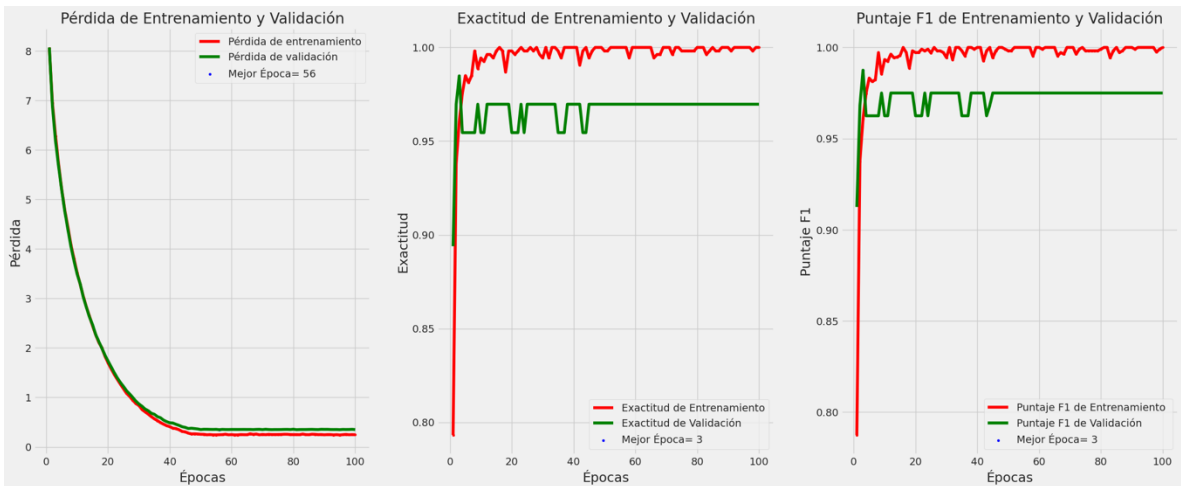
**Anexo 82- Gráficas de Desempeño EfficientNetV2B2, Época 75, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 83- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 84- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 85- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 86- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 87- Matriz de Confusión EfficientNetV2B2, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 88- Gráficas de Desempeño EfficientNetV2B2, Época 100, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 89- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 90- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 91- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 92- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 93- Matriz de Confusión InceptionResNetV2, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 94- Gráficas de Desempeño InceptionResNetV2, Época 50, Tamaño de Lote 70**

Fuente: Elaboración Propia




**Anexo 95- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 96- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote 20**

Fuente: Elaboración Propia




**Anexo 97- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia




**Anexo 98- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote 50**

Fuente: Elaboración Propia



**Anexo 99- Matriz de Confusión InceptionResNetV2, Época 75, Tamaño de Lote 70**


Fuente: Elaboración Propia



**Anexo 100- Gráficas de Desempeño InceptionResNetV2, Época 75, Tamaño de Lote**


**70**

Fuente: Elaboración Propia



**Anexo 101- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 20**


Fuente: Elaboración Propia



**Anexo 102- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote**


20

Fuente: Elaboración Propia



**Anexo 103- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 50**


Fuente: Elaboración Propia



**Anexo 104- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote**


**50**

Fuente: Elaboración Propia



**Anexo 105- Matriz de Confusión InceptionResNetV2, Época 100, Tamaño de Lote 70**

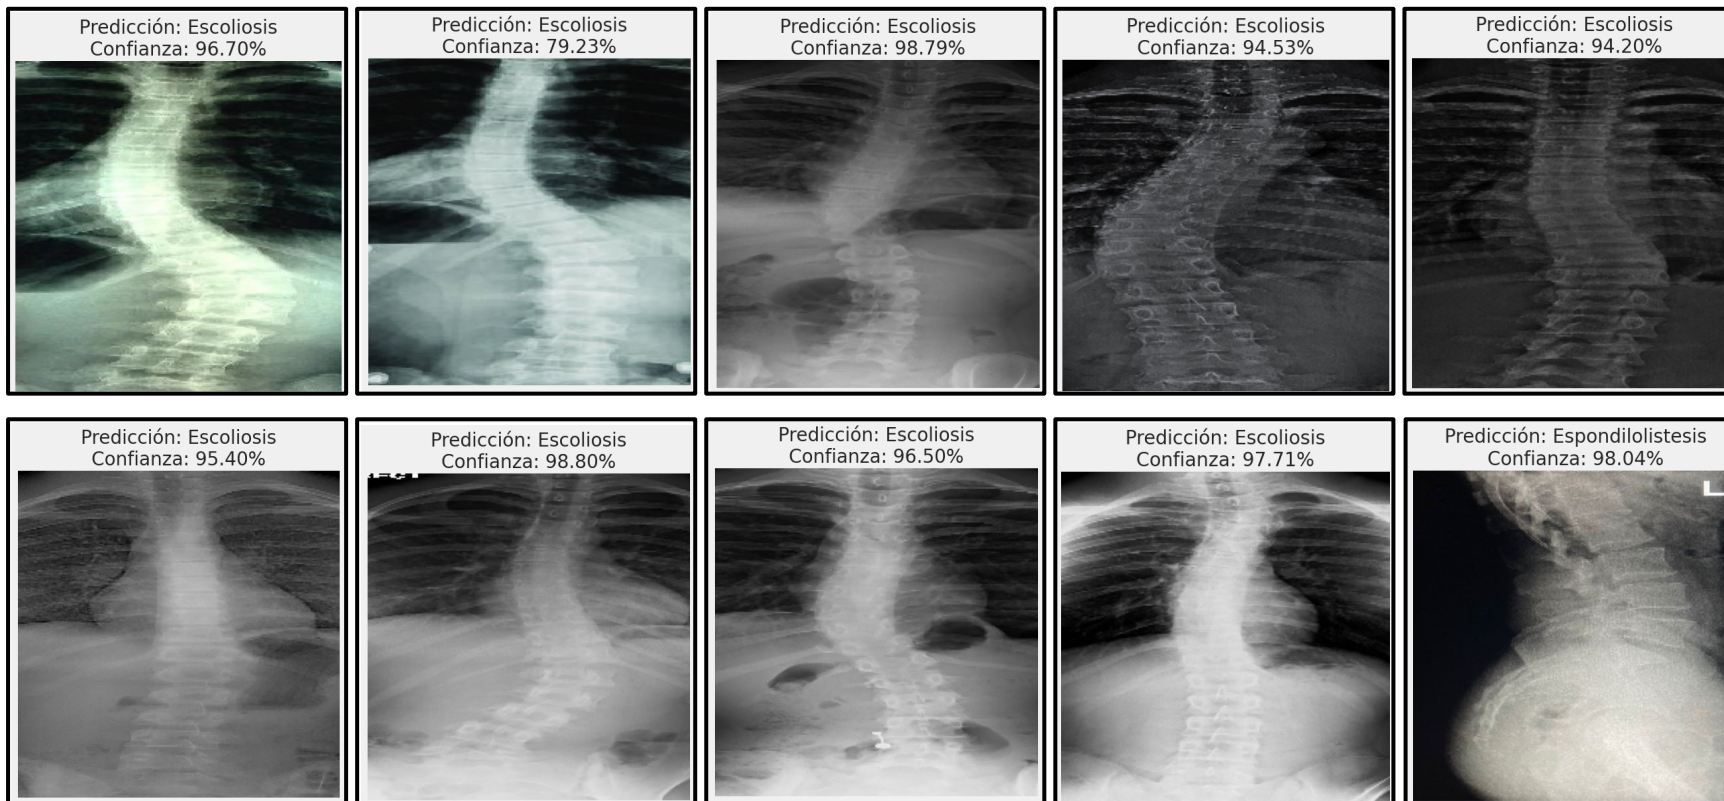
Fuente: Elaboración Propia



**Anexo 106- Gráficas de Desempeño InceptionResNetV2, Época 100, Tamaño de Lote**

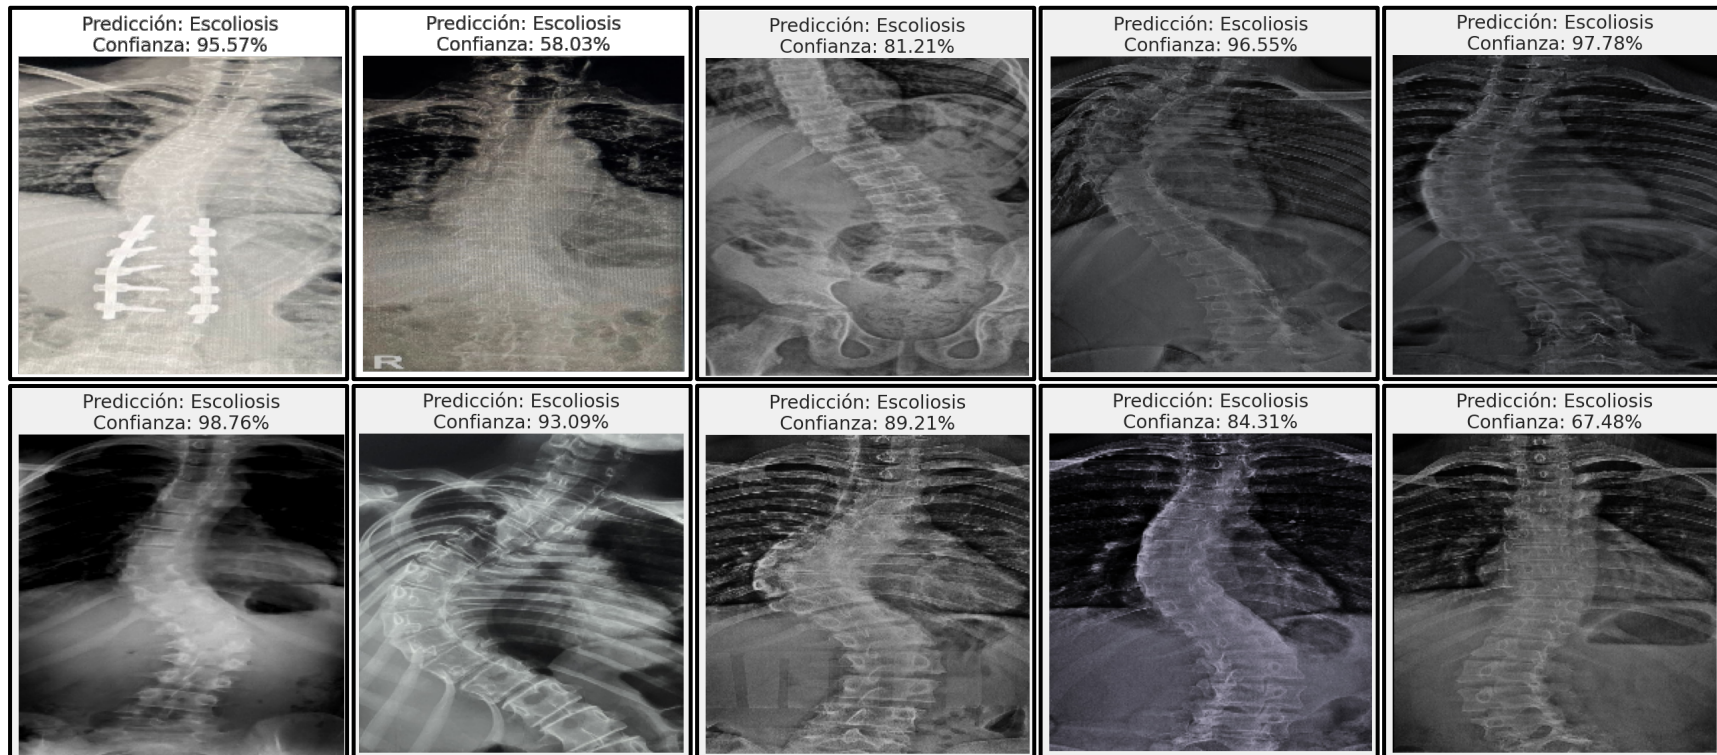
70

Fuente: Elaboración Propia



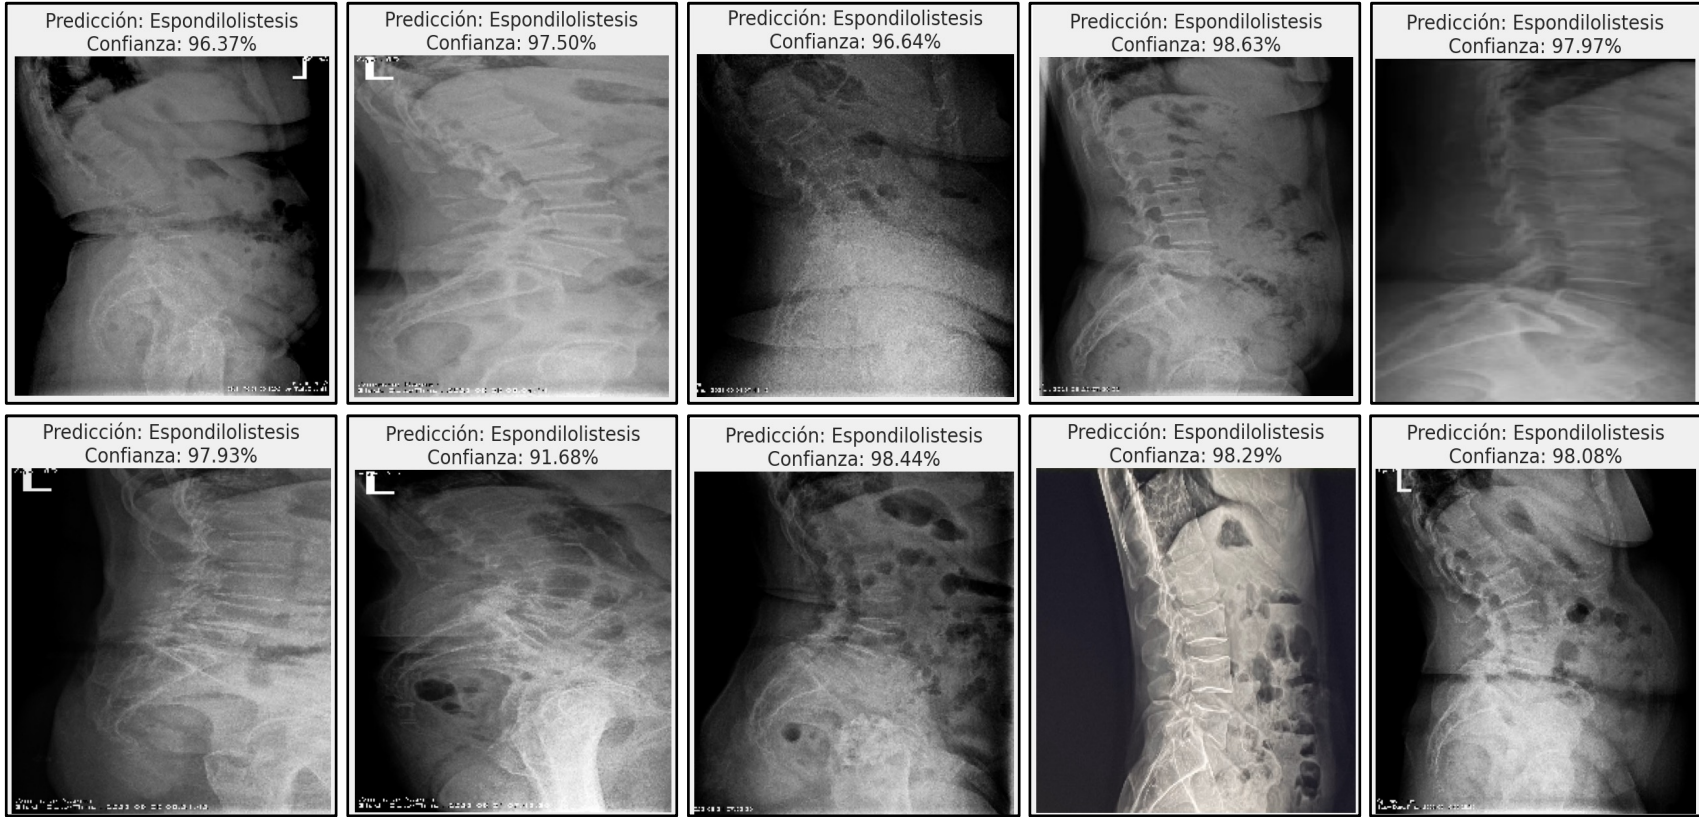
**Anexo 107- Predicciones de Escoliosis de EfficientNetV2B0**

Fuente: Elaboración Propia



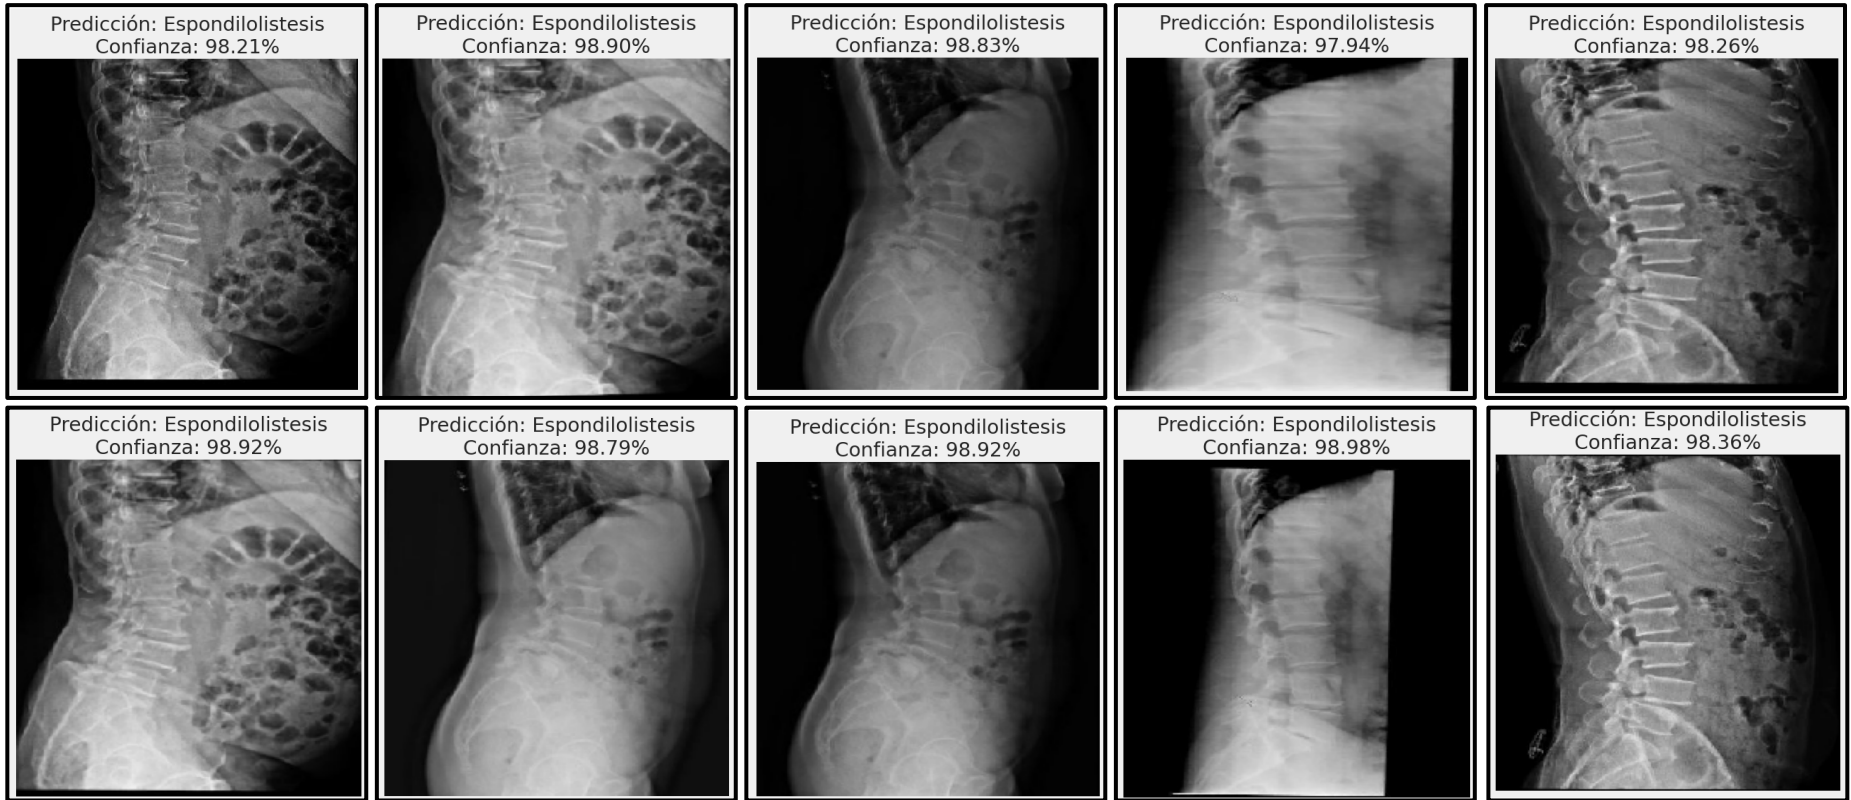
**Anexo 108- Predicciones de Escoliosis y Espondilolistesis de EfficientNetV2B0**

Fuente: Elaboración Propia



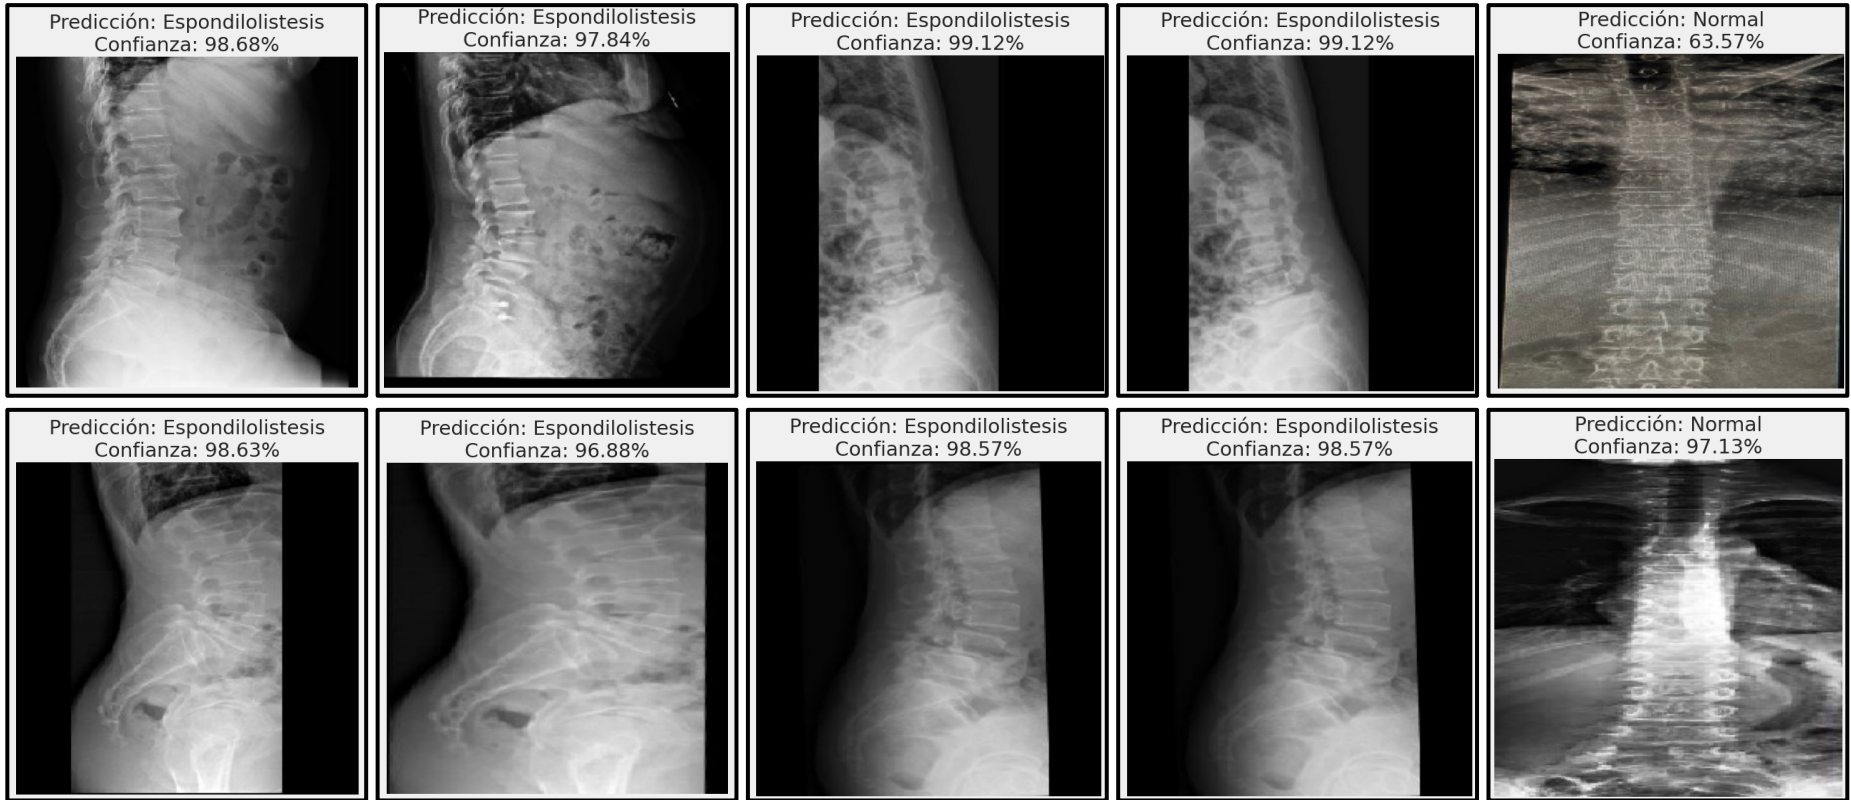
**Anexo 109- Predicciones de Espondilolistesis de EfficientNetV2B0**

Fuente: Elaboración Propia



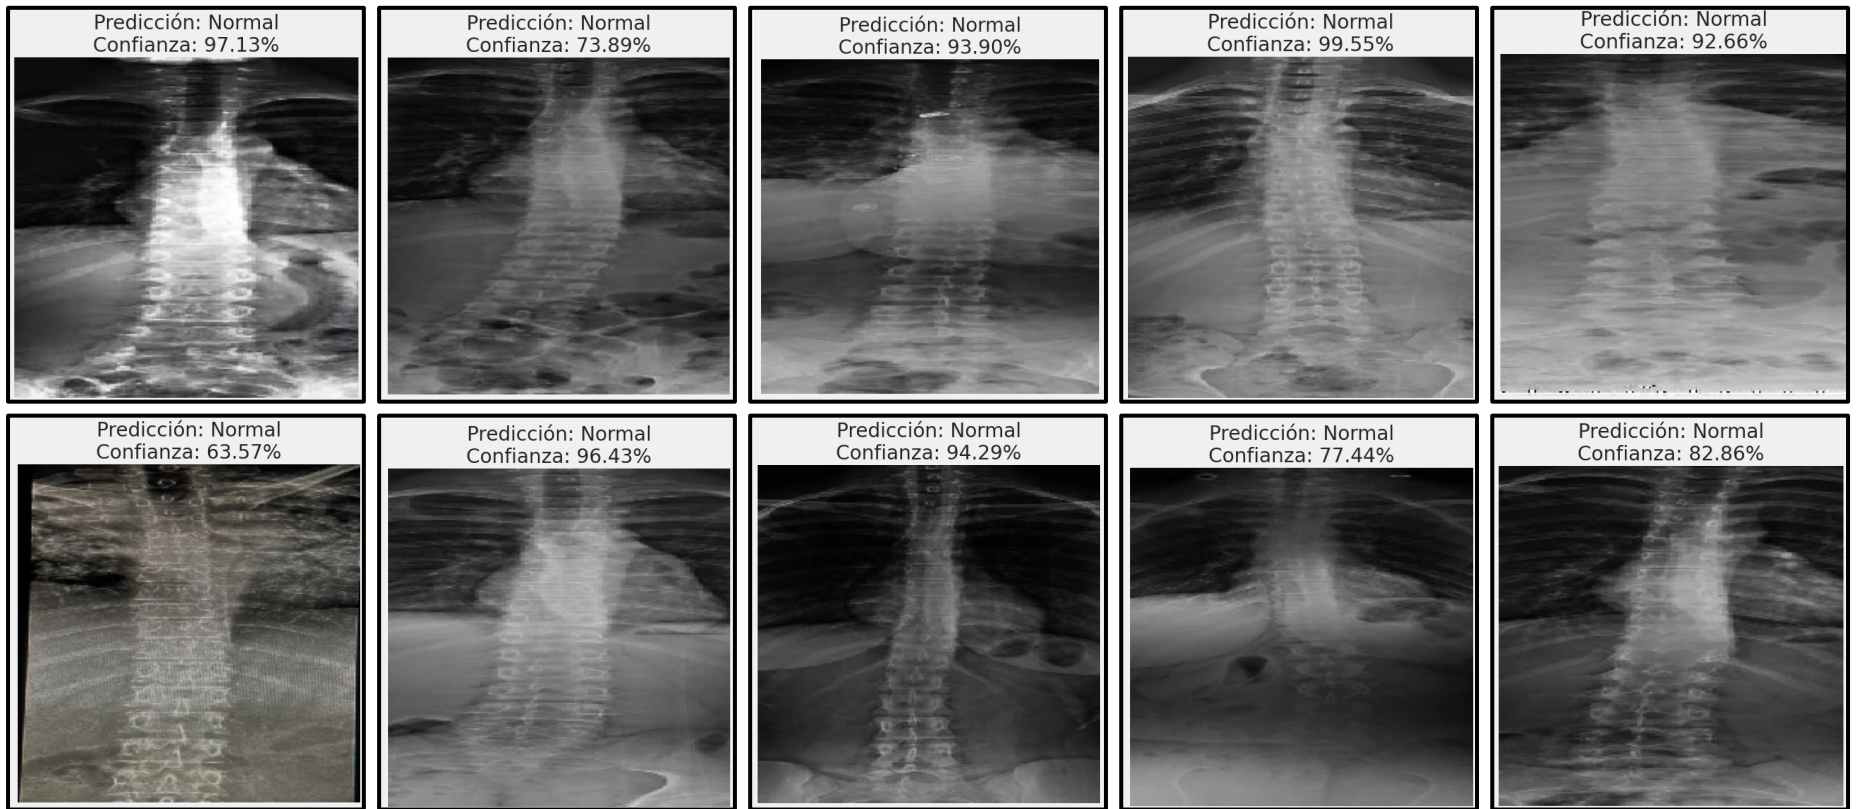
**Anexo 110- Predicciones de Espondilolistesis de EfficientNetV2B0**

Fuente: Elaboración Propia



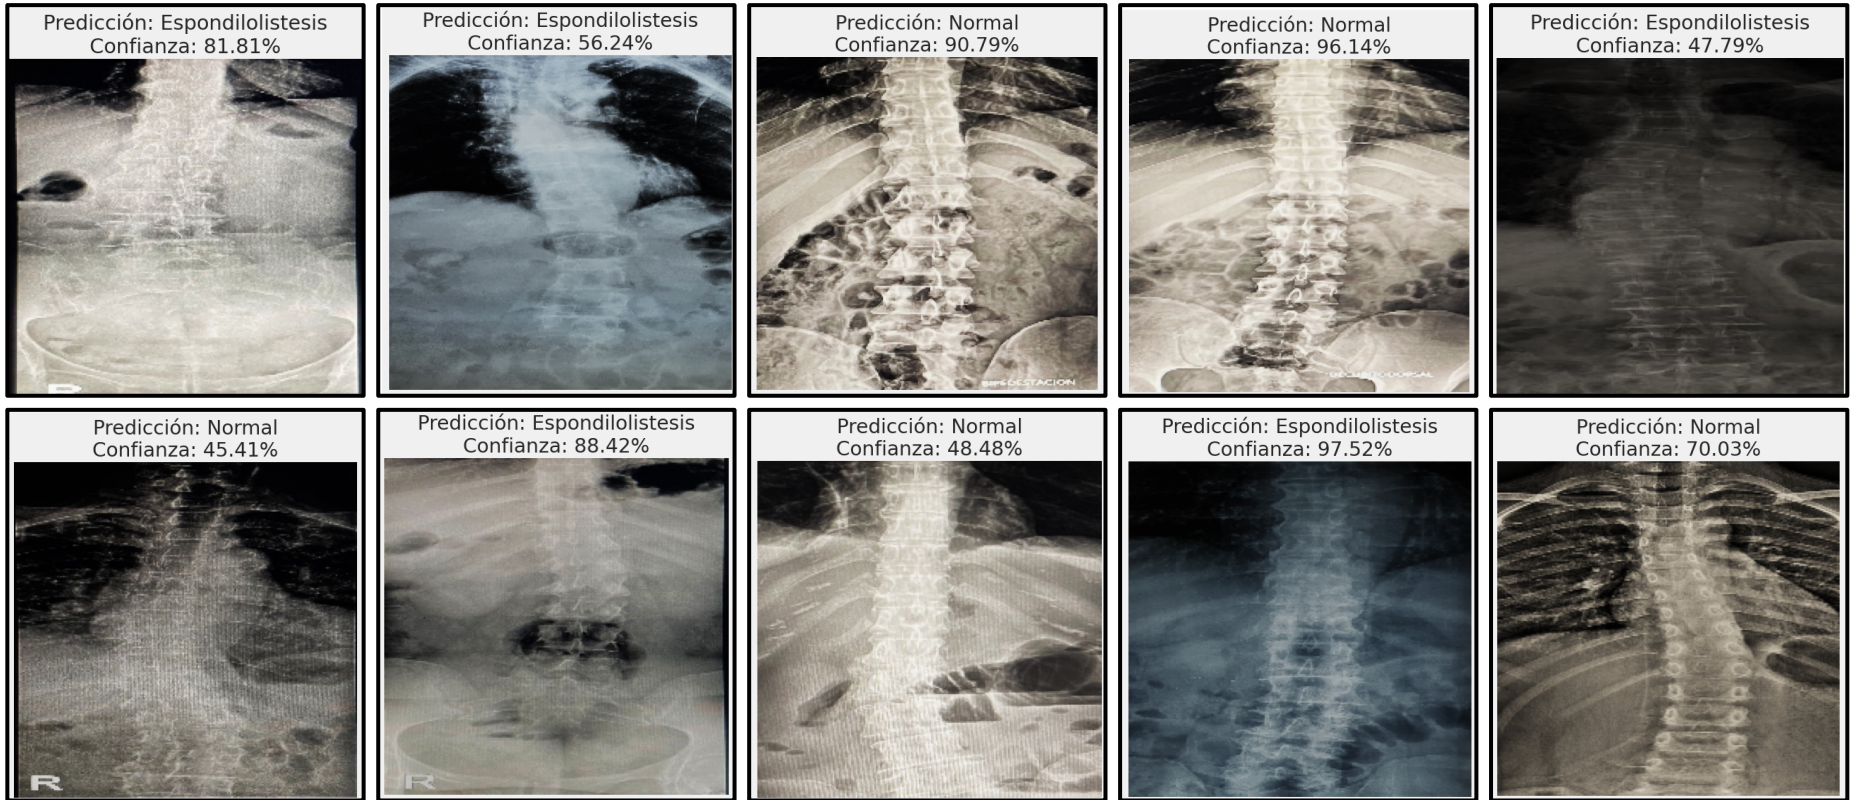
**Anexo 111- Predicciones de Espondilolistesis y Sin Escoliosis de EfficientNetV2B0**

Fuente: Elaboración Propia



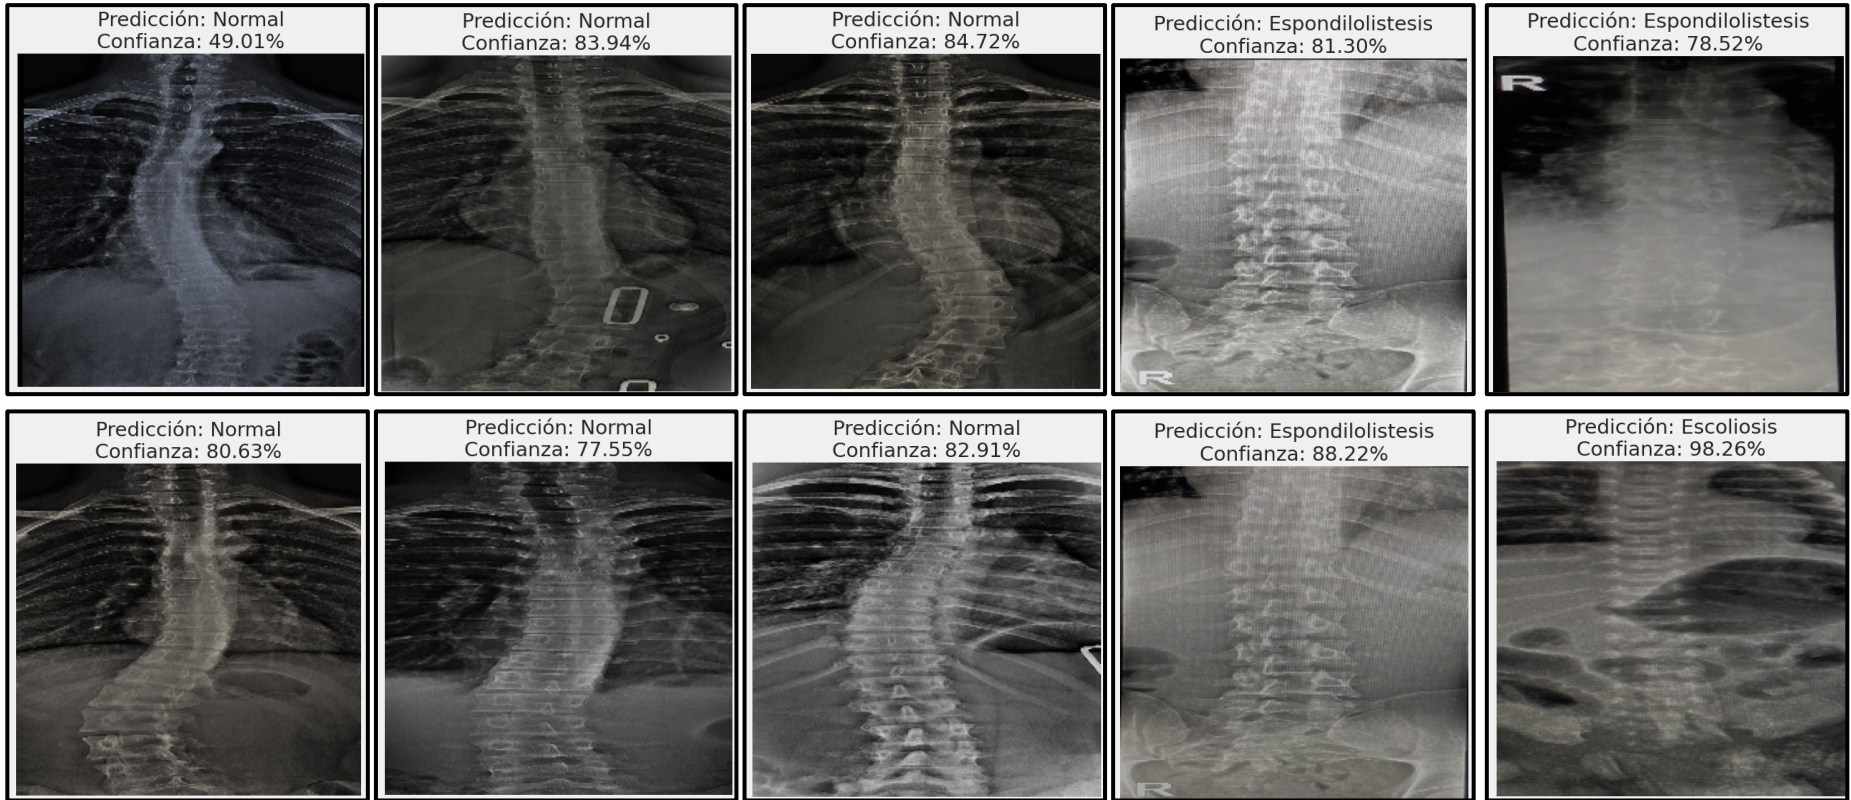
**Anexo 112- Predicciones de Sin Escoliosis de EfficientNetV2B0**

Fuente: Elaboración Propia





**Anexo 113- Errores en las predicciones de EfficientNetV2B0**

Fuente: Elaboración Propia



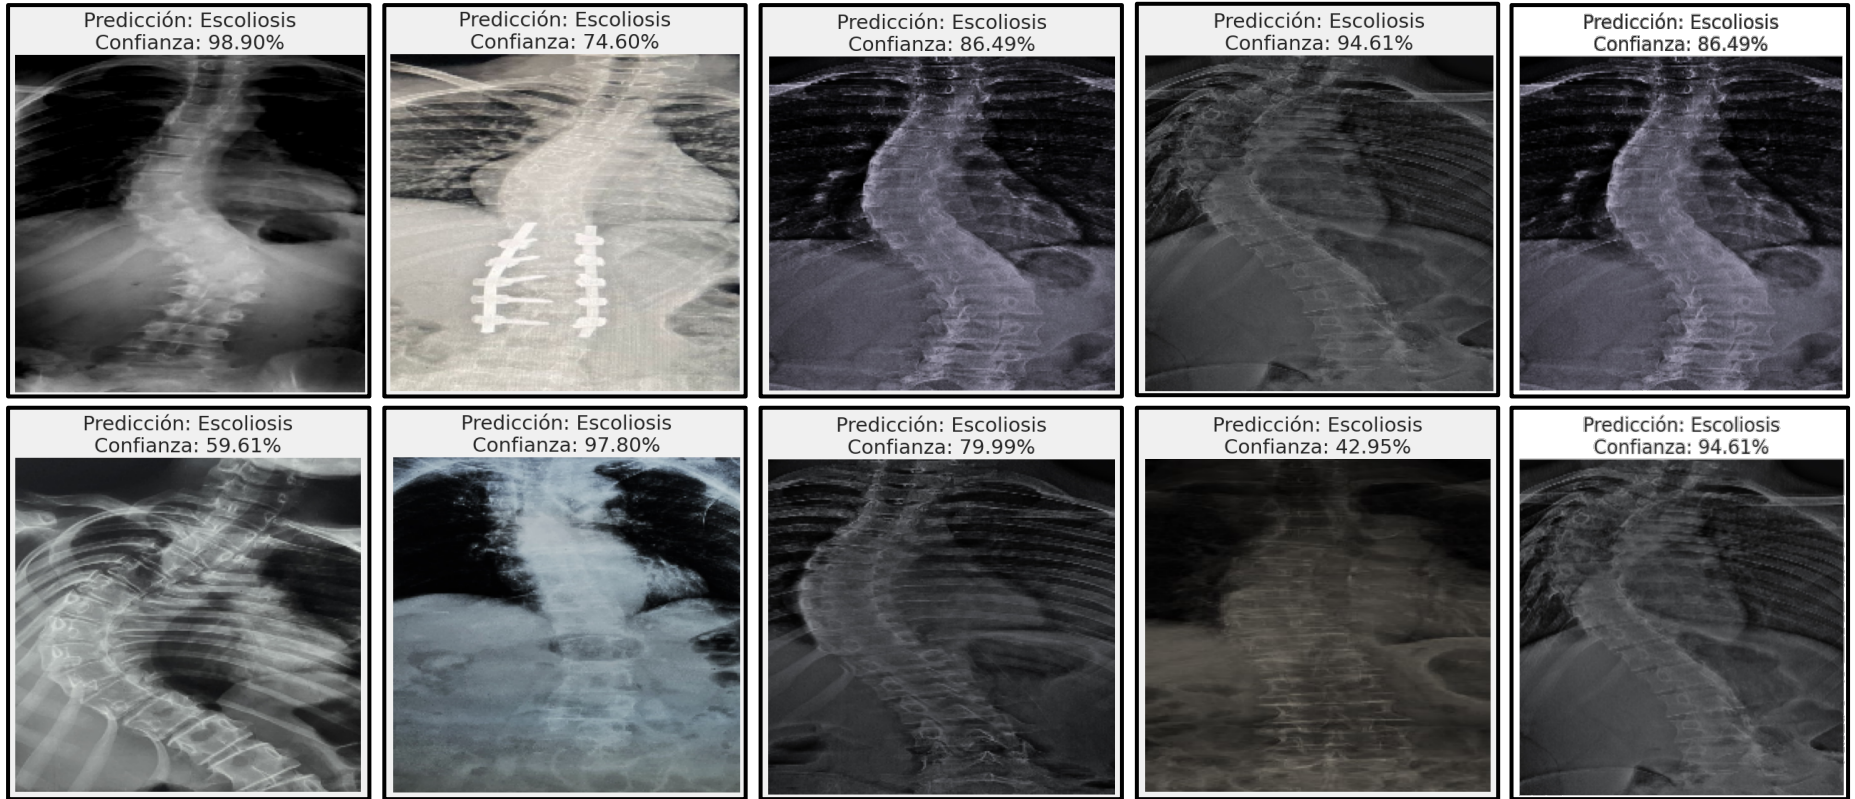
**Anexo 114- Errores en las predicciones de EfficientNetV2B0**

Fuente: Elaboración Propia



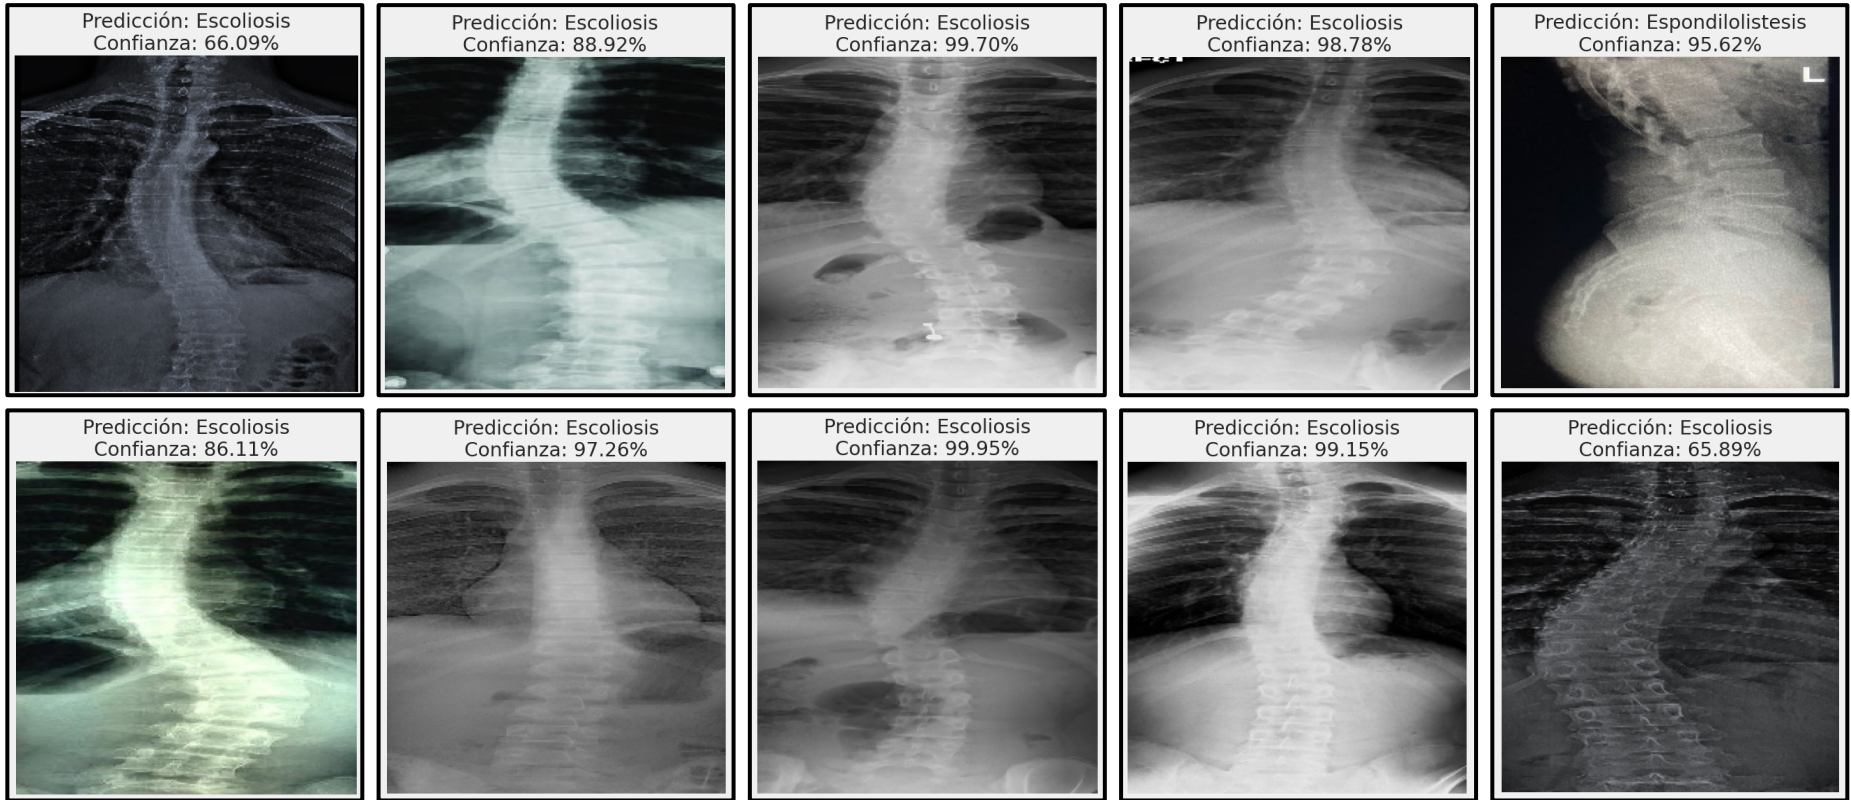
**Anexo 115- Errores en las predicciones de EfficientNetV2B0**

Fuente: Elaboración Propia



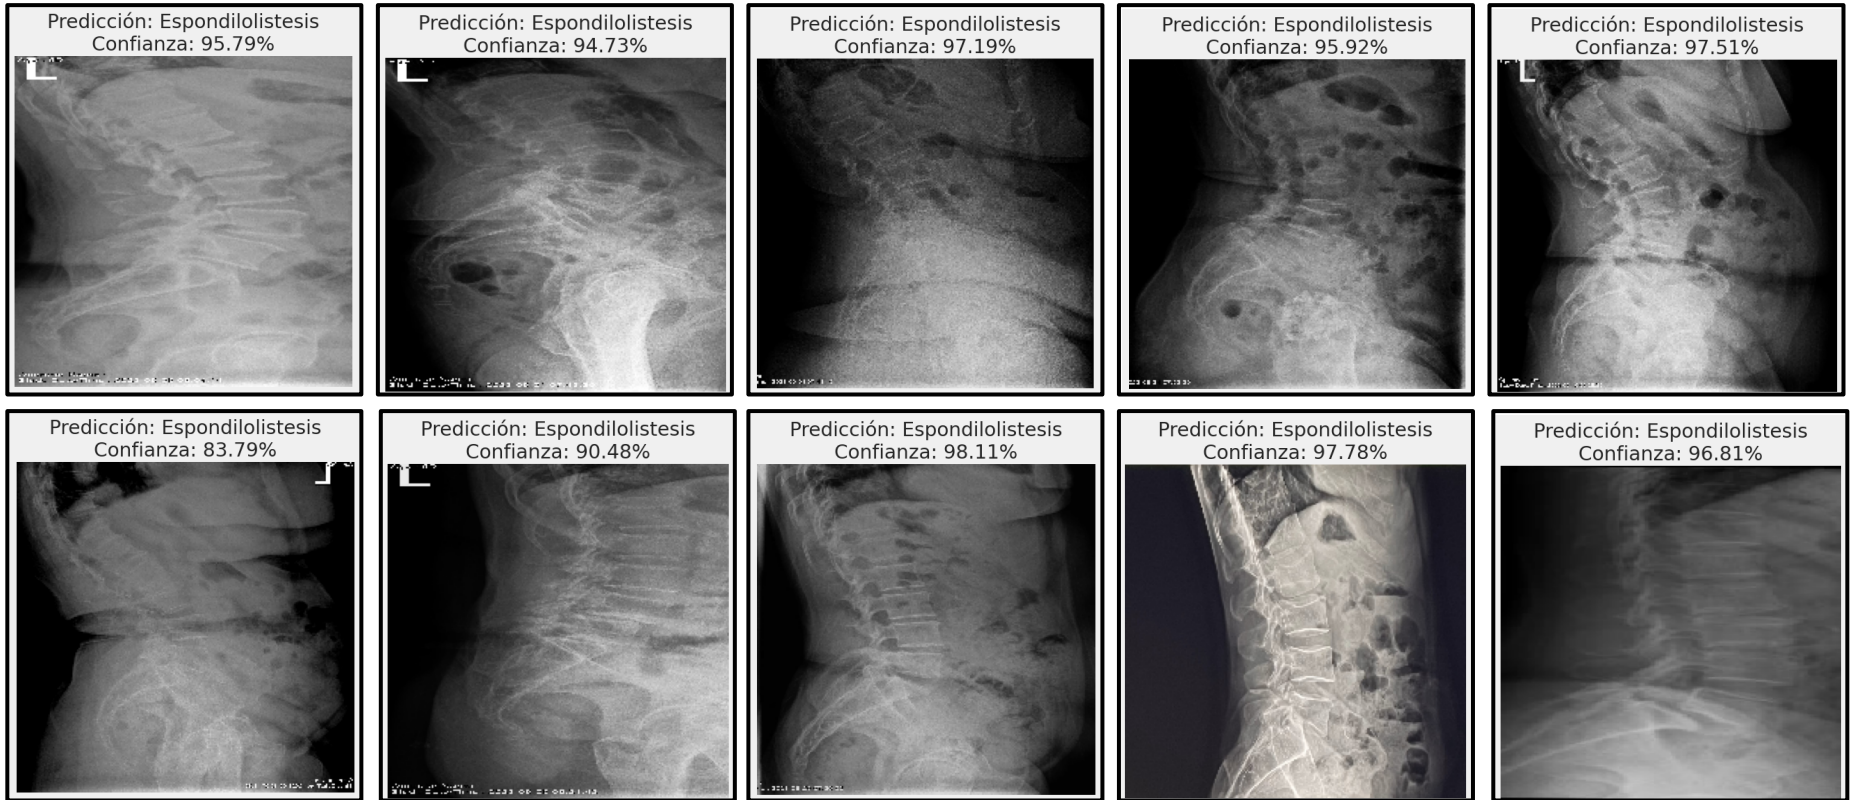
**Anexo 116- Predicciones de Escoliosis de EfficientNetV2B2**

Fuente: Elaboración Propia



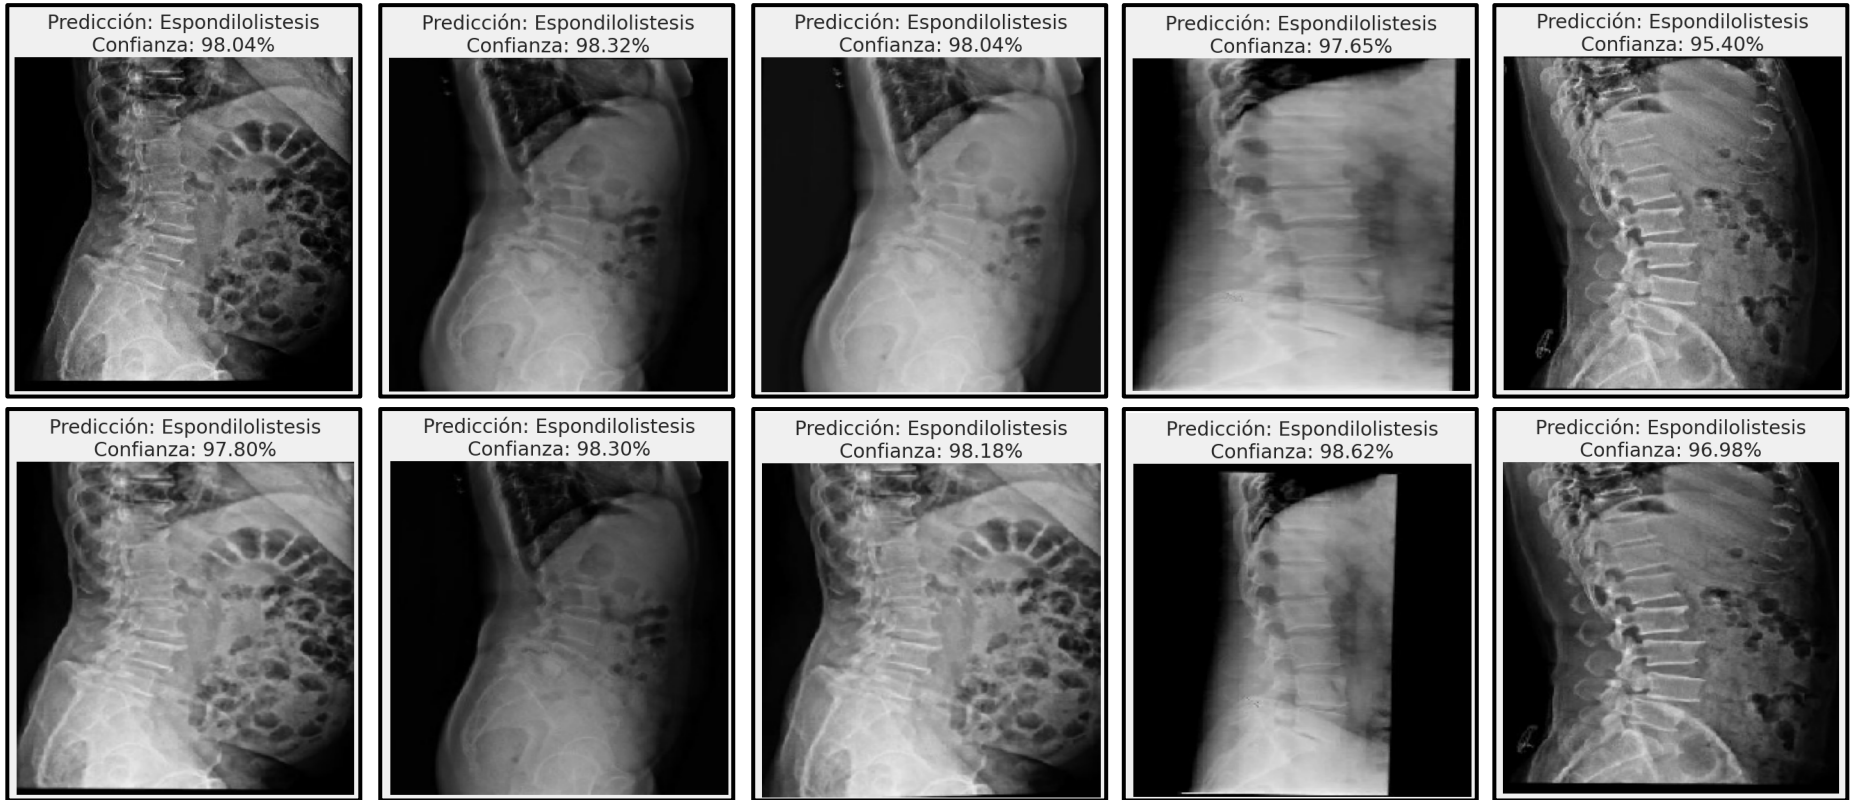
**Anexo 117- Predicciones de Escoliosis y Espondilolistesis de EfficientNetV2B2**

Fuente: Elaboración Propia



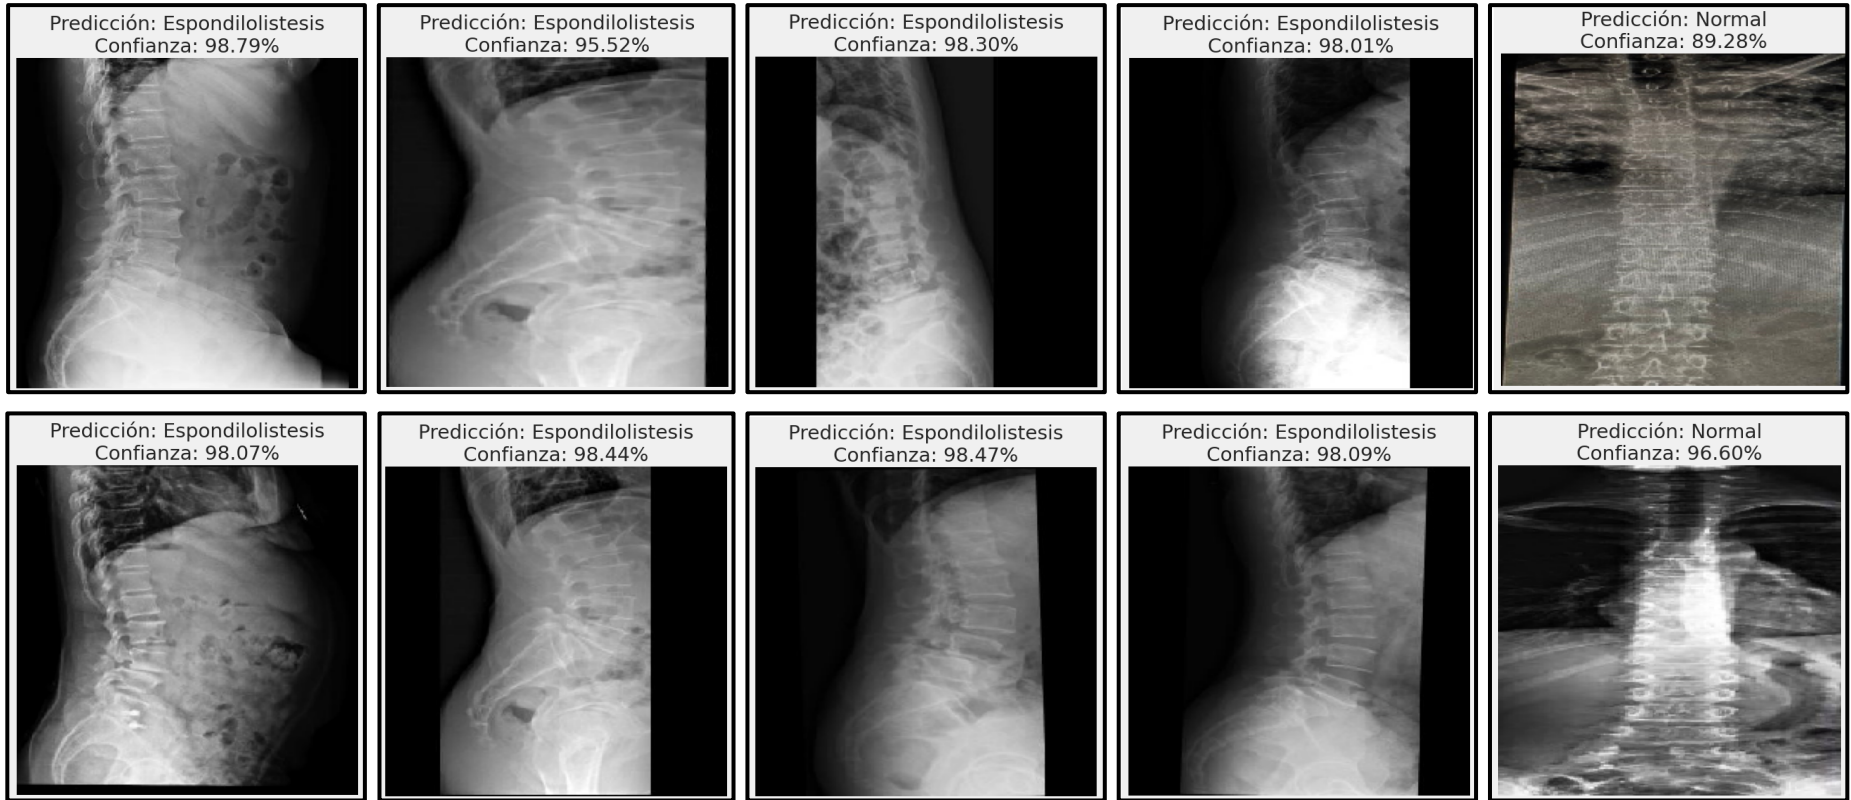
### Anexo 118- Predicciones de Espondilolistesis de EfficientNetV2B2

Fuente: Elaboración Propia



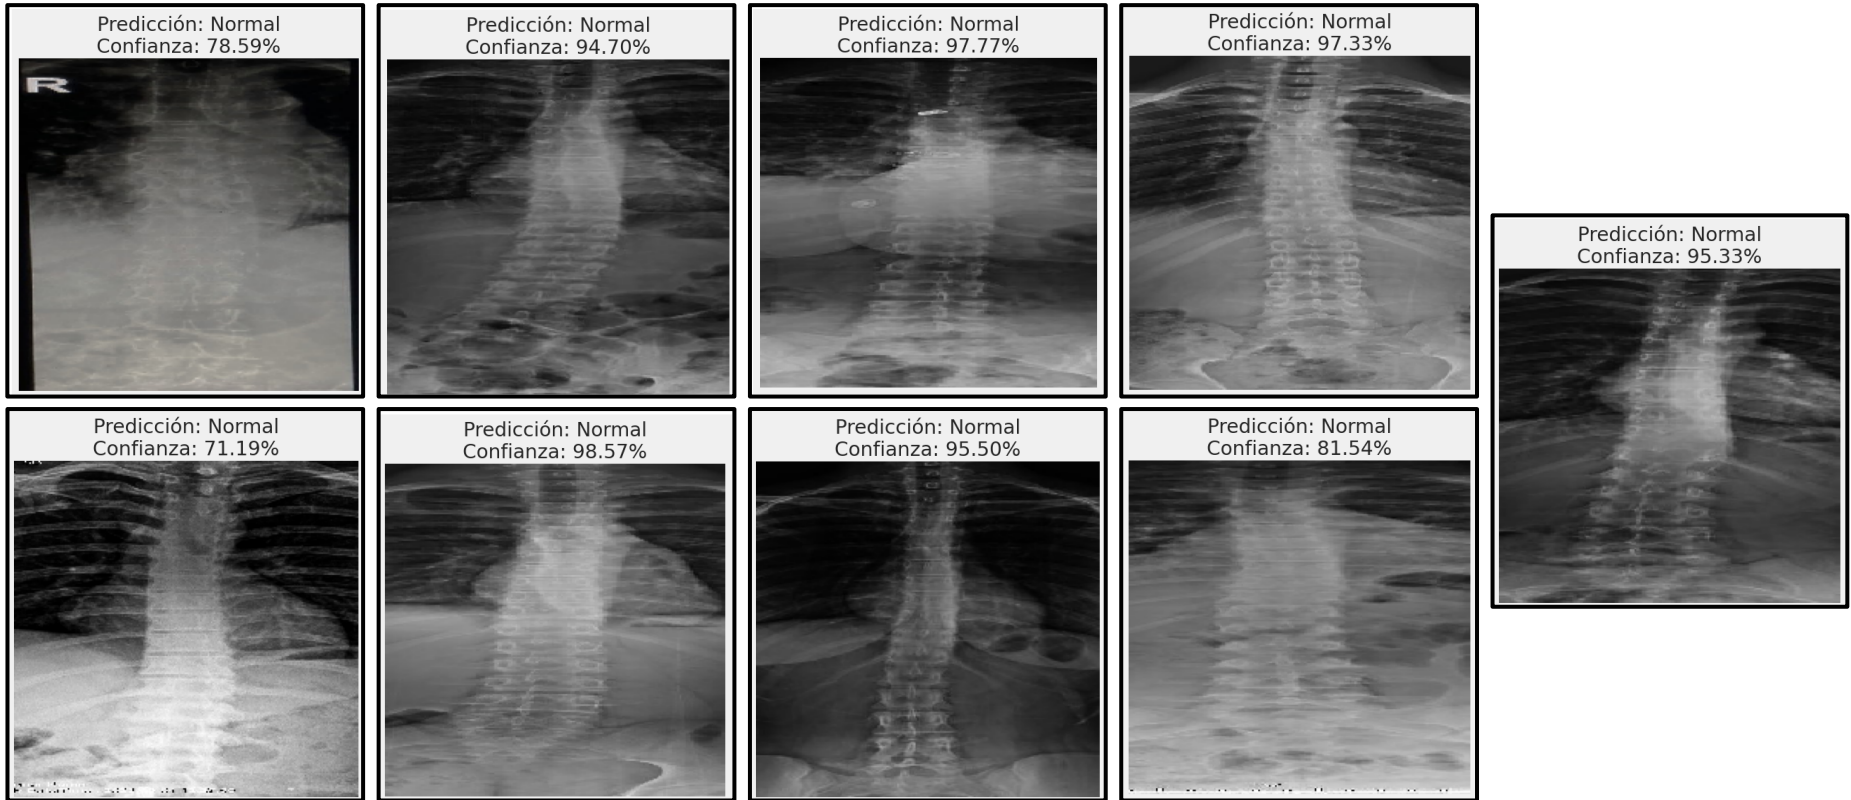
**Anexo 119- Predicciones de Espondilolistesis de EfficientNetV2B2**

Fuente: Elaboración Propia



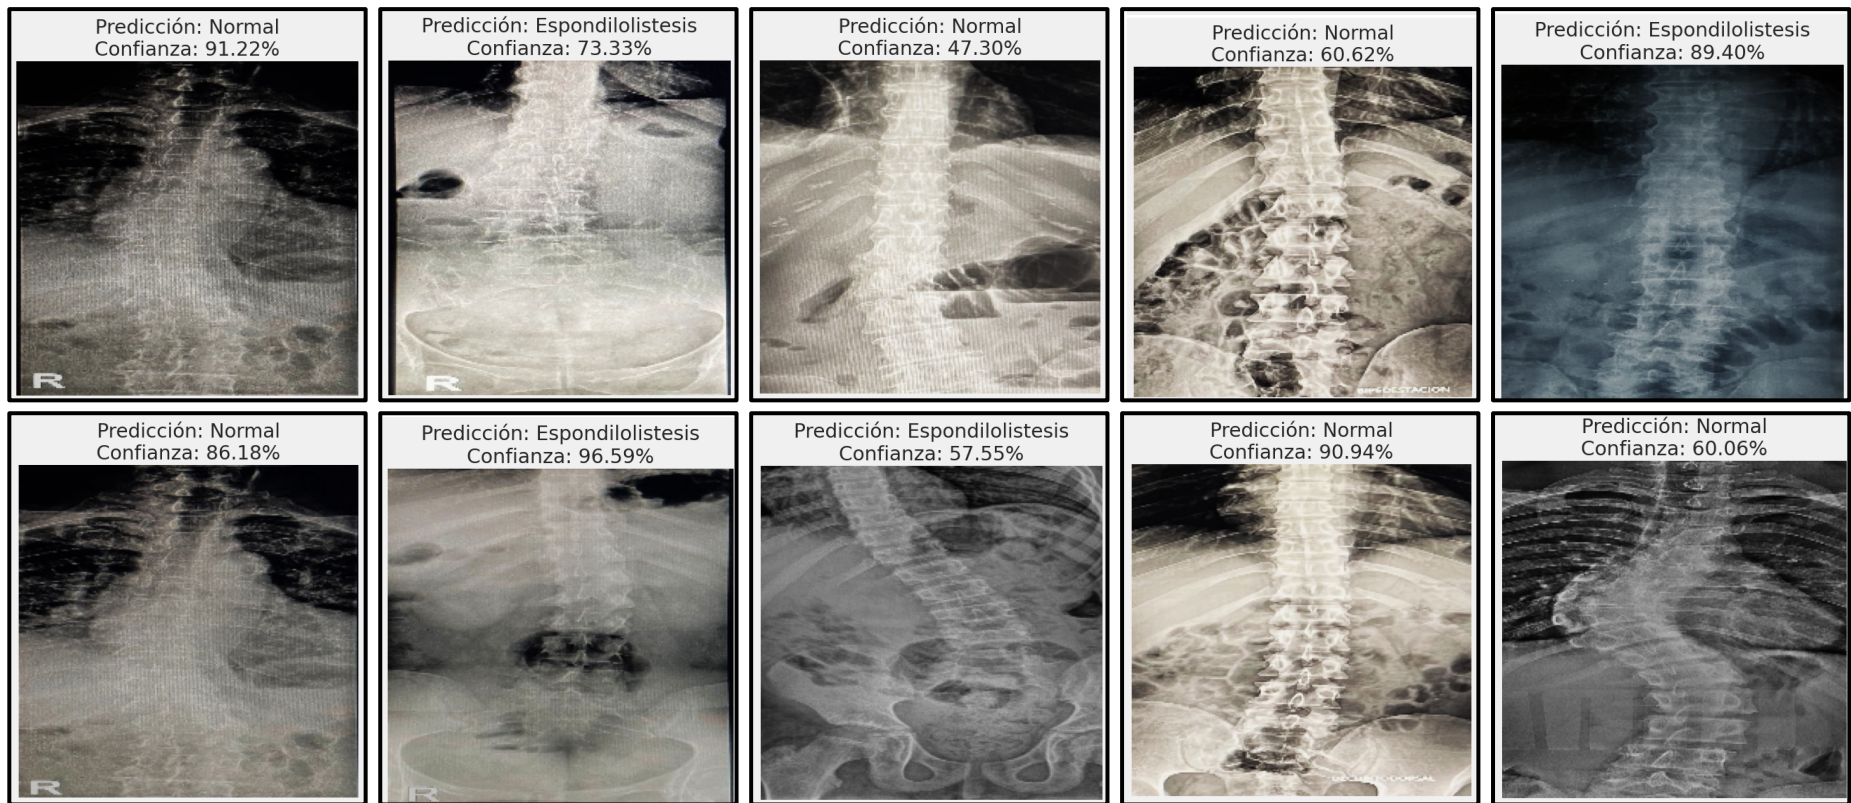
**Anexo 120- Predicciones de Espondilolistesis y Sin Escoliosis de EfficientNetV2B2**

Fuente: Elaboración Propia



**Anexo 121- Predicciones de Sin Escoliosis de EfficientNetV2B2**

Fuente: Elaboración Propia



**Anexo 122- Errores de Predicción de EfficientNetV2B2**



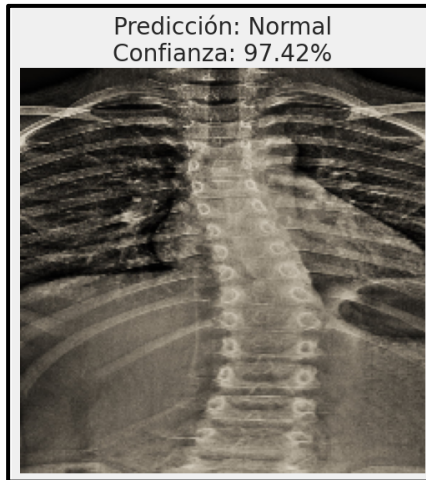



Fuente: Elaboración Pr

**Anexo 123- Errores de Predicción de EfficientNetV2B2 Anexo 124- Errores de Predicción de EfficientNetV2B2**

**Anexo 125- Errores de Predicción de EfficientNetV2B2**

**Anexo 126- Errores de Predicción de EfficientNetV2B2 Anexo 127- Errores de Predicción de EfficientNetV2B2**

**Anexo 128- Errores de Predicción de EfficientNetV2B2 Anexo 129- Errores de Predicción**






**Anexo 130- Errores de Predicción de EfficientNetV2B2**

Fuente: Elaboraci

**Anexo 131- Errores de Predicción de EfficientNetV2B2**

**Anexo 132- Errores de Predicción de EfficientNetV2B2**

**Anexo 133- Errores de Predicción de EfficientNetV2B2**



**Anexo 134- Errores de Predicción de EfficientNetV2B2**

Fuente: Elaboración Propia