



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



ESCUELA TÉCNICA  
SUPERIOR INGENIEROS  
INDUSTRIALES VALENCIA

**Curso Académico:**

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

*“Me lo contaron y lo olvidé; lo vi y lo entendí; lo hice y lo aprendí” - Confucio*

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **AGRADECIMIENTOS**

En primer lugar me gustaría agradecerle a mi tutor, Ignacio Bosch-Roig, la gran oportunidad de participar en este proyecto tan interesante. Pero en especial a mi cotutor, Ángel Alberich-Bayarri, por confiar en mí plenamente, ayudarme en todo momento y demostrarme que la Ingeniería Biomédica es un mundo apasionante.

También me gustaría darle las gracias a todo el equipo de GIBI 2<sup>30</sup> y de QUIBIM por acogerme como si fuese una más. En especial a Quique, Amadeo y Ana, por su colaboración y porque el verano ha sido más agradable trabajando junto a ellos.

A mis chicas, Sofía, Patricia, Julia y Estefanía, por este largo camino juntas. Sois lo más bonito que me ha regalado la carrera. A los 2/3 que me complementan, Clara y Begoña, porque sin ellas esto no hubiera sido posible.

Pero todo mi esfuerzo se lo dedico a mis padres, por su apoyo incondicional ahora y siempre y por ser mi ejemplo a seguir, un ejemplo de constancia y superación. A mi hermana, por serlo todo para mí. A Laura, por compartir conmigo la vida y en especial a Joan, por su cariño y confianza incuestionable y por no dejar de entenderme nunca.

**Muchísimas gracias a todos.**

Valencia, Septiembre del 2016

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **RESUMEN**

Uno de los exámenes más comunes realizados por los radiólogos es la radiografía de tórax, proporcionando información de las estructuras anatómicas más importantes del cuerpo. Este examen médico no invasivo es esencial para hacer frente a diversas alteraciones respiratorias asociadas con una alta tasa de mortalidad, mostrando un amplio rango de información potencial. El ojo humano de los radiólogos es muy preciso y ha sido altamente entrenado durante los últimos años. Sin embargo, cuando se usan imágenes para diagnosticar enfermedades de tórax hay ciertos cambios que son sutiles (a nivel de píxel) que permanecen ocultos a la interpretación visual. Recientemente, nuevas técnicas basadas en conceptos de inteligencia artificial han surgido en el campo de visión por ordenador. Se propone el uso de técnicas de aprendizaje profundo (*deep learning*), especialmente Redes Neuronales Convolucionales (CNN) en un sistema de diagnóstico asistido por ordenador (CAD) para ayudar a los radiólogos, llevando a cabo una primera tarea de *screening* de las radiografías de tórax. Se ha usado una base de datos de la Universidad de Indiana, disponibles en la plataforma Open-I, bajo demanda. Un subconjunto de 2242 imágenes de rayos X de tórax posteroanteriores fue seleccionado y dividido en diferentes grupos. Se ha implementado la CNN AlexNet (preentrenada con ImageNet) en MATLAB para extraer características de las imágenes y luego usarlas para entrenar a un clasificador binario. Para acelerar el cálculo de computación se ha hecho uso de unidad de procesamiento gráfico NVIDIA Tesla K40. Con todo ello se ha implementado satisfactoriamente una primera herramienta para ayudar a los radiólogos a distinguir entre rayos X de tórax sanos y patológicos obteniendo un área bajo la curva ROC (AUC) de 0.89, 0.90 para radiografías que presentan atelectasia frente a normales, 0.91 para cardiomegalia frente a normales, 0.91 entre sanas y efusión pleural, 0.85 para el grupo de nódulo y 0.88 para opacidades. Aunque no existan bases de datos de imágenes médicas adecuadamente etiquetadas y suficientemente grandes para entrenar una CNN desde 0, se puede hacer uso de una ya preentrenada como extractor automático de características para entrenar un clasificador SVM y obtener resultados relevantes en tareas de *screening* de detección de patologías.

**Palabras Clave:** Aprendizaje profundo, aprendizaje automático, clasificación, radiografías de tórax, imágenes médicas, pulmón, inteligencia artificial, diagnóstico asistido por ordenador, redes neuronales convolucionales.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **RESUM**

Un dels exàmens més comuns realitzats pels radiòlegs és la radiografia de tòrax, proporcionant informació de les estructures anatòmiques més importants del cos. Aquest examen mèdic no invasiu és essencial per fer front a diverses alteracions respiratòries associades amb una alta taxa de mortalitat, mostrant un ampli rang d'informació potencial. L'ull humà dels radiòlegs és molt precís i ha estat altament entrenat durant els últims anys. No obstant això, quan es fan servir imatges mèdiques per diagnosticar malalties de tòrax hi ha certs canvis que són subtils (a nivell de píxel) que romanen ocults a la interpretació visual. Recentment, noves tècniques basades en conceptes d'intel·ligència artificial han sorgit en el camp de visió per ordinador. En aquest treball es proposa l'ús de tècniques d'aprenentatge profund (deep learning), especialment Reds Neuronals Convolucionals (CNN) en un sistema de diagnòstic assistit per ordinador (CAD) per ajudar els radiòlegs, portant a terme una primera tasca de screening de les radiografies de tòrax. S'ha fet servir una base de dades d'imatges de raigs X de tòrax de la Universitat d'Indiana, disponibles a la plataforma Open-I, sota demanda. Un subconjunt de 2242 imatges de raigs X de tòrax anteroposteriors van ser seleccionades i dividides en diferents grups. S'ha implementat la CNN AlexNet (preentrenada amb ImageNet) en MATLAB per extreure característiques dels diferents grups i després usar-les per entrenar un classificador binari. Per accelerar el càlcul de computació s'ha fet ús d'una unitat de processament gràfic NVIDIA Tesla K40. Amb tot això s'ha implementat satisfactòriament una primera eina per ajudar els radiòlegs a distingir entre raigs X de tòrax sans i patològics obtenint una àrea sota la corba ROC (AUC) de 0.89, 0.90 per atelèctasi davant normals, 0.91 per cardiomegàlia davant normals, 0.91 entre sanes i efusió pleural, 0.85 per el grup de nòdul i 0.88 per opacitats. En conclusió, encara que no hi hagen bases de dades d'imatges mèdiques adequadament etiquetades i prou grans per entrenar una xarxa neuronal convolucional des de 0, es pot fer ús d'una ja preentrenada com extractor automàtic de característiques per entrenar un classificador SVM i obtenir resultats rellevants en tasques de screening de detecció de patologies.

**Paraules clau:** Aprenentatge profund, aprenentatge automàtic, classificació, radiografies de tòrax, imatge mèdica, pulmó, intel·ligència artificial, diagnòstic assistit per ordinador, xarxes neuronals convolucionals.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **ABSTRACT**

One of the most commonly performed examination by radiologists is chest radiography, providing information of the most important anatomical structures of the body. This non-invasive medical checkup is essential to face with diverse respiratory alterations associated with a high mortality rate, as they show a wide range of potential information. Human eye of radiologists is greatly precise and has been highly trained over the last years. However, when medical images are used to diagnose chest diseases, there are certain changes that are very subtle (pixel level) and remain hidden from visual interpretation. Recently, new techniques based on artificial intelligence concepts have emerged in the field of Computer Vision. We propose to use deep learning techniques, especially Convolutional Neural Networks (CNN) in a computer aided diagnostic (CAD) system to help radiologists to perform automated screening of chest radiographs. A database of chest X-ray images (7470 radiographs) from the Indiana University and available to use at the Open-I platform was used for the study. A subset of cases was selected consisting of 2242 A-P chest x-ray images divided in different groups. The AlexNet CNN (pretrained with ImageNet) has been implemented in Matlab to extract features from the different groups and use them to train a binary classifier. A NVIDIA Tesla K40 Graphics Processing Unit has been used to optimize the computing performance. A software tool was successfully implemented to help the radiologist to distinguish between healthy and abnormal chest x-ray obtaining an area under curve (AUC) of 0.89, 0.90 for atelectasis vs. normal ones, 0.91 between healthy and cardiomegaly, 0.91 for pleural effusion vs. normal ones, 0.85 for nodule group and 0.88 for opacities. Although there are no databases of medical images properly labeled and large enough to train a CNN from 0, using a pretrained CNN as an automatic feature extractor to train a SVM classifier is a good approach to get relevant results in chest X-ray screening tasks and in the detection of pathologies.

**Keywords:** Deep learning, machine learning, classification, chest X-rays, medical images, lung, artificial intelligence, computer-aided diagnosis, convolutional neural networks.

## **LISTA DE FIGURAS**

<b>Figura 1.</b> Caso de condena penal a un radiólogo por ausencia de informe radiológico en paciente con cáncer de pulmón.....	3
<b>Figura 2.</b> Diagrama de Gantt del Trabajo Fin de Grado.....	8
<b>Figura 3.</b> Diagrama de Gantt del Trabajo Fin de Grado desglosado.....	9
<b>Figura 4.</b> Espectro electromagnético extraído de en el que las radiaciones se agrupan según su radiación de onda, frecuencia y energía de un fotón.....	15
<b>Figura 5.</b> Tubo de rayos X.....	16
<b>Figura 6.</b> Radiografía PA de tórax normal en la que se observan las distintas estructuras a observar por el radiólogo.....	19
<b>Figura 7.</b> A la izquierda, radiografía de tórax normal. A la derecha, radiografía PA del tórax con atelectasia, mostrando un colapso del lóbulo superior izquierdo, una opacidad apical izquierda y un desplazamiento anterior de la cisura mayor.....	21
<b>Figura 8.</b> Anatomía cardíaca básica en radiología de tórax y relación cardiorácica.....	22
<b>Figura 9.</b> A la izquierda, radiografía de tórax normal, donde su ratio cardiorácico es menor del 50%. A la derecha, radiografía con cardiomegalia, donde la relación supera el 50%. .....	22
<b>Figura 10.</b> A la izquierda, derrame pleural subpulmonar derecho. Al centro, derrame pleural izquierdo. A la derecha, derrame pleural de gran magnitud.....	23
<b>Figura 11.</b> A la izquierda y a la derecha, presencia de un nódulo pulmonar solitario derecho. En el centro, radiografía con múltiples nódulos. ....	24
<b>Figura 12.</b> Ejemplos más comunes de opacidad en radiografía de tórax.....	24
<b>Figura 13.</b> Aproximación tradicional de machine learning o también llamada ‘shadow learning’ .....	25
<b>Figura 14.</b> Aproximación de deep learning en la clasificación de imágenes. Extracción de características y clasificación automática mediante un sistema de caja negra. ....	26
<b>Figura 15.</b> CNN entrenada para una reconocer clases como barco, bicicleta, coche... Para nuestra tarea en concreto, en lugar de extraer características de forma manual, se transfiere el conocimiento de la CNN entrenada. Extrae internamente características de las clases de la nueva tarea de reconocimiento que se usarán para entrenar un clasificador.....	27

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

<b>Figura 16.</b> Analogía del funcionamiento de una neurona en la Red Neuronal con una neurona del cerebro humano. El funcionamiento en la neurona es igual en las redes neuronales y en las convolucionales.....	28
<b>Figura 17.</b> Red neuronal simple de tres capas.....	29
<b>Figura 18.</b> Funcionamiento de una red neuronal convolucional. La capa de entrada roja es la imagen, siendo la altura y la anchura las dimensiones de la imagen y la profundidad, los tres canales de color (rojo, verde, azul).....	30
<b>Figura 19.</b> Funcionamiento de una imagen de 32x32 con la primera capa convolucional.....	32
<b>Figura 20.</b> Flujo de trabajo seguido en el desarrollo experimental.....	34
<b>Figura 21.</b> Flujo detallado de todo el proceso de experimentación y evaluación.....	35
<b>Figura 22.</b> Ejemplo de una imagen de rayos X de tórax de Open-I junto con su informe.....	36
<b>Figura 23.</b> 10 archivos tipo .tar.gz proporcionados por la red de hospitales de la Universidad de Indiana (7470 imágenes tipo DICOM).....	36
<b>Figura 24.</b> Pasar de DICOM a JPEG con IrfanView.....	37
<b>Figura 25.</b> Proceso de conversión de DICOM a JPEG llevado a cabo con éxito de las imágenes seleccionadas previamente en IrfanView.....	37
<b>Figura 26.</b> Primer fragmento (información de la primera imagen) del código JSON de las 100 primeras imágenes en el que se observa cómo se relaciona la parte principal del MeSH de cada imagen con el nombre de esta, para poderlas clasificar usando un programa propio desarrollado en Python.....	38
<b>Figura 27.</b> Esquema de AlexNet, una red neuronal convolucional entrenada a partir de ImageNet.....	41
<b>Figura 28.</b> En el entorno de MATLAB se observa que la arquitectura de la CNN importada coincide con el esquema y los parámetros de AlexNet ( <b>convnet.Layers</b> ).....	42
<b>Figura 29.</b> Características de bajo nivel tras las activaciones de la primera capa de la CNN (manchas, ejes...).....	43
<b>Figura 30.</b> Descripción final de los datos introducidos para entrenamiento y test del clasificador.....	45
<b>Figura 31.</b> Tabla que contiene 1736 observaciones (868 Anormales y 868 Normales) en las filas y 4096 características obtenidas de forma automática por AlexNet de cada una de ellas, junto con las etiquetas de cada Estructura necesaria que se debe introducir para entrenar un clasificador con la Classification Learner App de MATLAB.....	46
<b>Figura 32.</b> Preparación de los datos en la App Clasificación Learner de MATLAB.....	47



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

<b>Figura 33.</b> Comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App. Se puede observar que el mejor modelo clasificador se consigue con un SVM de kernel lineal.....	47
<b>Figura 34.</b> Segunda parte de la Comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App.....	48
<b>Figura 35.</b> Tercera parte de la comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App.....	48
<b>Figura 36.</b> Descripción de los datos para entrenamiento y test del clasificador: Atelectasia vs. Normal.....	49
<b>Figura 37.</b> Descripción de los datos para entrenamiento y test del clasificador: Cardiomegalia vs. Normal.....	49
<b>Figura 38.</b> Descripción de los datos para entrenamiento y test del clasificador: Efusión pleural vs. Normal.....	50
<b>Figura 39.</b> Descripción de los datos para entrenamiento y test del clasificador: Nódulo vs. Normal.....	50
<b>Figura 40.</b> Descripción de los datos para entrenamiento y test del clasificador: Efusión pleural vs. Normal.....	51
<b>Figura 41.</b> Ejemplo de curva ROC.....	56
<b>Figura 42.</b> Ejemplo de AUC de la curva ROC de la Figura.....	56
<b>Figura 43.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Anormal y Normal.....	59
<b>Figura 44.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 43).....	59
<b>Figura 45.</b> Curva ROC Y AUC en la clasificación entre categoría Anormal y Normal.....	60
<b>Figura 46.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Atelectasia y Normal.....	60
<b>Figura 47.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 46).....	61
<b>Figura 48.</b> Curva ROC Y AUC en la clasificación entre categoría Atelectasia y Normal.....	61
<b>Figura 49.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Cardiomegalia y Normal.....	62
<b>Figura 50.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 49).....	62
<b>Figura 51.</b> Curva ROC Y AUC en la clasificación entre categoría Cardiomegalia y Normal.....	63
<b>Figura 52.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Efusión pleural y Normal.....	63

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

<b>Figura 53.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 52).....	64
<b>Figura 54.</b> Curva ROC Y AUC en la clasificación entre categoría Efusión pleural y Normal.....	64
<b>Figura 55.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Nódulo y Normal.....	65
<b>Figura 56.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 55).....	65
<b>Figura 57.</b> Curva ROC Y AUC en la clasificación entre categoría Nódulo y Normal.....	66
<b>Figura 58.</b> Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Opacidad y Normal.....	66
<b>Figura 59.</b> Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión (Figura 59).....	67
<b>Figura 60.</b> Curva ROC Y AUC en la clasificación entre categoría Opacidad y Normal.....	67
<b>Figura 61.</b> Comparación de los distintos índices de rendimiento clínico obtenidos en las diferentes tareas de clasificación.....	69
<b>Figura 62.</b> Comparación de nuestro proyecto con estudios previos.....	70
<b>Figura 63.</b> Interfaz del sistema antes de ser usada.....	71
<b>Figura 64.</b> Imagen de radiografía de tórax PA introducida en el sistema.....	71
<b>Figura 65.</b> Clasificación de la imagen en Normal tras pulsar en Radiológico Reading y pasar la imagen por el primer clasificador propuesto.....	71
<b>Figura 66.</b> Clasificación de la imagen en Anormal tras pulsar en Radiológico Reading y pasar la imagen por el primer clasificador propuesto.....	72
<b>Figura 67.</b> Clasificación de la imagen en Anormal tras pulsar en Radiological reading y pasar la imagen por el sistema final. Primer ejemplo.....	72
<b>Figura 68.</b> Clasificación de la imagen en Anormal tras pulsar en Radiological reading y pasar la imagen por el sistema final. Segundo ejemplo.....	73
<b>Figura 69.</b> DeepLIR en caso de radiografía de tórax Normal.....	74
<b>Figura 70.</b> DeepLIR en caso de radiografía de tórax Anormal.....	74

## **LISTA DE TABLAS**

<b>Tabla 1.</b> Paquetes de trabajo llevados a cabo a lo largo del Trabajo de Fin de Grado y la duración de los mismos.....	5
<b>Tabla 2.</b> Primer paquete de trabajo.....	6
<b>Tabla 3.</b> Segundo paquete de trabajo.....	6
<b>Tabla 4.</b> Tercer paquete de trabajo.....	6
<b>Tabla 5.</b> Cuarto paquete de trabajo.....	7
<b>Tabla 6.</b> Quinto paquete de trabajo.....	7
<b>Tabla 7.</b> Sexto paquete de trabajo.....	7
<b>Tabla 8.</b> Séptimo paquete de trabajo.....	8
<b>Tabla 9.</b> Primer paquete de trabajo añadido.....	10
<b>Tabla 10.</b> Segundo paquete de trabajo añadido.....	11
<b>Tabla 11.</b> Agrupación final de las imágenes de las clases patológicas según su término MeSH.....	39
<b>Tabla 12.</b> Agrupación final de las imágenes de rayos X de tórax AP lista para empezar el proceso de extracción de características.....	40
<b>Tabla 13.</b> Estructura y parámetros de AlexNet, una CNN preentrenada.....	41
<b>Tabla 14.</b> Matriz de confusión general.....	53
<b>Tabla 15.</b> Rendimiento de distintos clasificadores entrenados para una tarea de clasificación entre Normal y Anormal.....	57
<b>Tabla 16.</b> Índices de rendimiento clínico de todos los clasificadores.....	68
<b>Tabla 17.</b> Costes de personal necesario para la elaboración del proyecto.....	XVIII.1
<b>Tabla 18.</b> Costes de software necesario para la elaboración del proyecto.....	XVIII.2
<b>Tabla 19.</b> Costes de hardware necesario para la elaboración del proyecto.....	XVIII.3
<b>Tabla 20.</b> Presupuesto total del proyecto desglosado.....	XVIII.4

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **LISTA DE ACRÓNIMOS**

ACC	Precisión
AUC	Área Debajo de la Curva Roc ( <i>Area Under the Curve</i> )
CAD	Diagnóstico Asistido por Ordenador ( <i>Computer Aided Diagnosis</i> )
CPU	Unidad Central de Procesamiento ( <i>Central processing Unit</i> )
CNN	Red Neuronal Convolucional ( <i>Convolutional Neural Network</i> )
DICOM	Imagen digital y comunicación en medicina ( <i>Digital Imaging and Communication in Medicine</i> )
FNR	Ratio de Falsos Negativos ( <i>False Negative Rate</i> )
FPR	Ratio de Falsos Positivos ( <i>False Positive Rate</i> )
GIBI2 <sup>30</sup>	Grupo de Investigación Biomédica por la Imagen
GPU	Unidad de Procesamiento Gráfico ( <i>Graphics Processor Unit</i> )
GUI	Interfaz Gráfica de Usuario ( <i>Graphical User Interface</i> )
HOG	Histograma de gradientes orientados ( <i>Histogram of Oriented Gradients</i> )
JPEG	<i>Joint Photographic Experts Group</i>
JSON	<i>Java Script Object Notation</i>
LBP	Patrones Binarios Locales ( <i>Local Binary Patterns</i> )
MeSH	<i>Medical Subject Headings</i>
PA	Posteroanterior
PPV	Valor de Positivos Predichos ( <i>Predicted Positive Value</i> )
ROC	Característica operativa del receptor ( <i>Receiver Operating Charactristics</i> )
SPC	Especificidad ( <i>Specificity</i> )
SURF	Aceleración de Características Robustas ( <i>Speed Up Robust Features</i> )
SVM	Máquinas de Vector Soporte ( <i>Support Vector Machines</i> )
TB	Tuberculosis
TFG	Trabajo de Fin de Grado
TNR	Ratio de Verdaderos Negativos ( <i>True Negative Rate</i> )
TPR	Ratio de Verdaderos Positivos ( <i>True Positive Rate</i> )

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **TABLA DE CONTENIDOS**

<b>AGRADECIMIENTOS</b> .....	III
<b>RESUMEN</b> .....	IV
<b>RESUM</b> .....	V
<b>ABSTRACT</b> .....	VI
<b>LISTA DE FIGURAS</b> .....	VII
<b>LISTA DE TABLAS</b> .....	XI
<b>LISTA DE ACRÓNIMOS</b> .....	XII
<b>DOCUMENTO I: MEMORIA</b> .....	XVI
<b>CAPÍTULO 1. INTRODUCCIÓN</b> .....	1
1.1 Estructura del documento .....	1
1.2 Motivación .....	2
1.3 Plan de trabajo .....	5
1.3.1 Paquetes de trabajo.....	5
1.3.2 Diagrama de Gantt.....	8
1.3.3 Incidencias y modificaciones .....	9
<b>CAPÍTULO 2. OBJETIVOS</b> .....	12
2.1 Objetivo general .....	12
2.2 Objetivos específicos .....	12
<b>CAPÍTULO 3. ANTECEDENTES</b> .....	14
3.1 Antecedentes clínicos .....	14
3.1.1 Diagnóstico por la imagen .....	14
3.1.2 Física de los rayos X .....	14
3.1.3 Rayos X en medicina .....	17
3.1.4 Radiografía de tórax .....	18
3.1.5 Patologías de interés en el proyecto .....	20
3.1.6 Digitalización de la radiografía de tórax.....	25

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

3.2 Antecedentes técnicos.....	25
<b>CAPÍTULO 4. MATERIAL Y MÉTODOS .....</b>	<b>34</b>
4.1 Requisitos.....	35
4.2 Preparación de la base de datos.....	35
4.2.1 Obtención de los datos.....	35
4.2.2 Organización y estructuración de los datos.....	37
4.3 Extracción de características.....	40
4.4 Entrenamiento de un clasificador.....	46
4.5 Otras tareas de clasificación .....	48
4.6 Uso de GPU .....	51
4.7 Implementación del sistema.....	51
<b>CAPÍTULO 5. RESULTADOS .....</b>	<b>53</b>
5.1 Índices del rendimiento clínico .....	53
5.2 Resultados experimentales.....	56
5.2.1 Comparativa entre los distintos clasificadores entrenados .....	57
5.2.2 Evaluación del SVM en distintas tareas de clasificación.....	58
5.3 Valoración de los resultados y comparación con otros estudios.....	68
5.4 Interfaz gráfica y funcionamiento del sistema.....	70
5.5 Demostración del video comercial del sistema .....	73
<b>CAPÍTULO 6. CONCLUSIONES Y LÍNEAS FUTURAS.....</b>	<b>75</b>
<b>REFERENCIAS.....</b>	<b>77</b>
<b>DOCUMENTO II: PRESUPUESTO .....</b>	<b>XVII</b>
1. OBJETIVO.....	1
2. PRESUPUESTO DESGLOSADO .....	1
2.1 Costes de personal .....	1
2.2 Costes de software .....	2
2.3 Costes de hardware.....	3
3. PRESUPUESTO TOTAL DEL PROYECTO .....	4
<b>DOCUMENTO III: ANEXOS .....</b>	<b>XVIII</b>
1. PROGRAMA CON PYTHON .....	1

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

2. PRIMERA VERSIÓN DEL SISTEMA CON MATLAB.....	3
3. VERSIÓN FINAL DE LA INTERFAZ GRÁFICA CON MATLAB.....	6
4. ABSTRACT PARA ESOI/EUSOMII.....	9

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

# MEMORIA

## DOCUMENTO I

TRABAJO FIN DE GRADO

**“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”**

Belén Fos Guarinos

Curso 2015-2016



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

# **CAPÍTULO 1. INTRODUCCIÓN**

## **1.1. ESTRUCTURA DEL DOCUMENTO**

El **DOCUMENTO I: MEMORIA** está dividido en 6 capítulos, detallados a continuación:

- En el **CAPÍTULO 1. INTRODUCCIÓN** se expone la estructura del trabajo y se plantea la problemática que ha movido al desarrollo de mismo. Además, se puede encontrar el plan de trabajo propuesto y su correlación con el llevado a cabo en la realidad (inicio y fin de los distintos paquetes de trabajo y tareas, su duración, el orden de unas respecto a otras, el diagrama de Gantt y las incidencias y modificaciones en cuanto a organización).
- El **CAPÍTULO 2. OBJETIVOS** remarca la propuesta alrededor de la cual va a girar el proyecto, tanto de forma general como de forma específica.
- El **CAPÍTULO 3. ANTECEDENTES** sitúa al lector en el campo clínico y técnico que enmarcan al proyecto, partiendo desde conocimientos básicos hasta llegar a una revisión de los trabajos de los últimos años relacionados con la separación de placas de tórax en normales y patológicas, mediante la extracción de características de las imágenes de forma manual y automática. Además, se expone la analogía del Deep Learning (Redes Neuronales Convolucionales) con el procesamiento de información llevado a cabo en el cerebro humano y se revisan las publicaciones recientes que han empleado esta última metodología para la clasificación de imagen médica.
- El **CAPÍTULO 4. MATERIAL Y MÉTODOS** declara las principales aportaciones de este Trabajo Fin de Grado, describe las etapas seguidas durante el desarrollo del mismo y especifica las tecnologías y materiales utilizados para alcanzar el objetivo final.
- En el **CAPÍTULO 5. RESULTADOS** se exponen los resultados estadísticos obtenidos tras el desarrollo e implementación del proyecto. También se muestra la interfaz gráfica desarrollada, a modo de entorno visual sencillo para permitir al radiólogo la interacción con el sistema.
- En el **CAPÍTULO 6. CONCLUSIONES** se hace un breve repaso del trabajo, haciendo hincapié en las ideas principales. Además, se evalúan los resultados obtenidos y se proponen posibles trabajos futuros.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **1.2. MOTIVACIÓN**

Pese al aumento de técnicas como la tomografía computarizada, la ecografía y la resonancia magnética, la radiología simple sigue siendo la técnica más realizada en los servicios de radiodiagnóstico, recibiendo cerca del 75% de la actividad (Valdés et al, 2013). Esto se debe a una amplia disponibilidad, fácil realización, reproductibilidad, baja dosis de radiación, bajo coste, y aceptabilidad como técnica de detección en numerosas enfermedades (Valdés y Morales, 2015). Se trata del primer estudio que se les realiza a muchos pacientes, importante en la decisión de si son necesarias más pruebas o no.

Uno de los exámenes más comúnmente realizado por radiólogos es la radiografía de tórax, pues proporciona información de las estructuras anatómicas más importantes del cuerpo. Se trata de una herramienta de análisis esencial para hacer frente a diversas alteraciones del tórax y de las estructuras óseas asociadas con una alta tasa de mortalidad, pues muestra una amplia gama de información potencial. Además, es una de las modalidades de imagen más difíciles de interpretar, y requiere una curva de aprendizaje alta (Eisen et al, 2006; Herman et al, 1975).

El ojo humano de los radiólogos es altamente preciso y ha sido muy entrenado durante los últimos años. Sin embargo, cuando se utilizan radiografías de tórax para detectar enfermedades, hay ciertos cambios que son muy sutiles (a nivel de píxel) que permanecen ocultos a la interpretación visual dificultando la diferenciación de algunas patologías.

Es por ello que una de las principales motivaciones del desarrollo de este proyecto es poder asistir a los radiólogos en la lectura de radiografías de tórax, aumentando la precisión y la eficiencia en el servicio de radiología, llegando a percibir estas alteraciones inapreciables a simple vista, mediante el diseño de un sistema asistido por ordenador (CAD) basado en técnicas de inteligencia artificial.

Pero además de este, existen otros problemas asociados a la radiografía de tórax que han motivado al desarrollo del sistema propuesto en este trabajo.

La parte más importante del proceso radiológico es el informe, hasta el punto en el que los radiólogos son útiles en la medida en que lo son sus informes (Tardáguila et al, 2004; Martí et al 2004). Es la conclusión de la actividad radiológica y su producto final (Berlin, 2000). Del mismo se deriva importante información pronóstica y decisiones terapéuticas por parte del clínico responsable del paciente. El informe radiológico es un tipo de informe médico, medio de comunicación entre el clínico y el radiólogo y se trata de un documento medicolegal (Coakley et al, 2003).

No obstante, muchos radiólogos están dejando de lado el informar la radiología convencional para centrarse en tareas más llamativas o mejor remuneradas provocando que no se informe la totalidad de las mismas. Al ser la radiografía de tórax una de las principales puertas de acceso o el primer paso en el servicio de urgencias, muchas de estas imágenes pasan al especialista sin ser informadas, pidiendo solo su informe si éste lo estima necesario e interpretando él mismo la imagen cayendo en

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

el gran mito de que si no se informa es que su informe no es necesario. Sin embargo, como se puede apreciar en (Urrutia et al, 2001) la fiabilidad de los médicos de urgencias interpretando este tipo de imágenes es baja con respecto a los radiólogos. No hay datos globales sobre el número de exploraciones radiológicas no informadas en el Sistema Sanitario Español pero datos aislados evidencian que se dejan de informar entre el 30 y el 75 % de las radiografías, la mayoría correspondiendo con la radiología simple (Valdés y Morales, 2015).

La mala práctica de dejar sin informar las radiografías convencionales se ha hecho evidente en un caso que ha llevado a la condena penal de un radiólogo por no informar una radiografía de tórax. Esta sentencia se fundamenta en que el médico especialista en radiodiagnóstico no realizó un informe en el que valorara la radiografía de tórax, por una parte, y en que el clínico que tuvo el error diagnóstico, no echara en falta esa valoración y diera por buena la prueba. Este caso ha mostrado el riesgo legal que presenta una mala praxis en el servicio de radiología (Valle, 2011).



Figura 1. Caso de condena penal a un radiólogo por ausencia de informe radiológico en paciente con cáncer de pulmón.

Sin embargo, esto no queda en un caso aislado y lejano. Algunos datos disponibles en el Grupo de Ingeniería Biomédica por la Imagen del Hospital Universitario y Politécnico La Fe revelan que solo

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

aproximadamente el 10% de la radiografía de tórax del mismo en el 2015 se encuentra informada, dificultando el hecho de dar calidad y seguridad asistencial si se deja de informar.

La propuesta del presente trabajo gira entorno a solucionar este potencial problema y evitar que ocurran casos como el presentado anteriormente en el Hospital La Fe. La herramienta planteada, con la colaboración de GIBI 2<sup>30</sup> y QUIBIM, para la separación automática (mediante técnicas de inteligencia artificial) de placas de tórax en patológicas y sanas podría usarse también como una primera tarea de screening de todas las imágenes de rayos X torácicas almacenadas y no informadas. Las clasificadas como anormales se pondrían como tarea pendiente a revisar e informar de forma urgente por el especialista radiólogo, acelerando el proceso y priorizando las posibles patológicas. La finalidad sería el avisar al paciente en caso de que no se haya hecho, con tiempo suficiente para poner solución, evitando a su vez los problemas médico-legales mostrados. Es imprescindible realizar este esfuerzo e ir aumentando de forma progresiva el número de radiografías que se informan. Ganarán todos, pero sobre todo, ganará el paciente.

Finalmente, otro motivo que ha movido a plantear este proyecto es la situación en los países subdesarrollados. La tuberculosis (TB) es la segunda enfermedad más común causa de muerte por enfermedades infecciosas. El 95% de las muertes por TB ocurren en países de ingresos bajos y medios. Los 6 países que sostienen el mayor número de casos en 2014 son: India, Nigeria, Pakistan, China y Sudáfrica. Exactamente, la región de África tuvo el 28% de los casos de ese mismo año, además de la carga más grave en relación con la población: 281 casos por cada 100000 habitantes, más del doble del promedio global (133). La falta de solución a este problema en particular (TB) se debe a obstáculos como la falta de diagnóstico. Los países del Tercer Mundo no presentan recursos económicos y de personal suficientes como para ser capaces de diagnosticar esta enfermedad potencial. Diagnosticar TB es un gran reto (Taghizade et al, 2016).

En (Stefan et al, 2014) se propone una aproximación automática para detectar manifestaciones de TB en radiografías de tórax, capaz de leer rayos-X permitiendo una tarea de screening masiva de una gran población que no puede ser manejada de forma manual. Esta tecnología de screening coste efectiva podría ser un primer paso hacia diagnósticos más potentes de TB y hacia la disminución de la carga de la enfermedad, equilibrando la balanza entre el tamaño de la población afectada y los servicios de radiología disponibles. Podría ser una primera solución en zonas donde el papel del radiólogo es casi inexistente, siendo solamente necesario enseñar a un profesional técnico a usar el software que presentará la decisión en un formato simple y comprensible por médicos regionales que tienen poco o nada de fondo en radiología.

Esta idea ha motivado al desarrollo del presente proyecto, viendo un nicho en los países del Tercer Mundo mediante la detección automática, no solo de TB, sino de múltiples enfermedades cardiopulmonares con signos visibles en las radiografías de tórax, cubriendo de forma relativamente económica la figura del radiólogo, no presente de forma sustancial. El sistema propuesto se basa en métodos de aprendizaje profundo (*deep learning*) para el screening de radiografías torácicas, haciendo

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

uso de Redes Neuronales Convolucionales en la extracción de características de forma automática. Esta forma de extraer características podría llegar a superar la propuesta de (Stefan et al, 2014), mediante la imitación del cerebro humano en la lectura de imágenes de rayos X.

### 1.3. PLAN DE TRABAJO

A continuación se detalla la planificación temporal seguida en este Trabajo de Fin de Grado. Se ha seguido el plan de trabajo establecido con ciertas incidencias y modificaciones se exponen en el apartado 1.3.3.

#### 1.3.1. Paquetes de trabajo

Los paquetes de trabajo consisten en agrupaciones de las actividades o tareas en grandes bloques separando aquellas distintas conceptualmente e independientes entre sí.

En la Tabla 1 se observan los paquetes de trabajo que fueron planificados de forma inicial para alcanzar los objetivos del trabajo en un tiempo determinado. Cada paquete de trabajo aparece junto con la duración (en días) que se le destinó al mismo.

**Tabla 1.** Paquetes de trabajo llevados a cabo a lo largo del Trabajo de Fin de Grado y la duración de los mismos.

Nº	PAQUETE DE TRABAJO	DURACIÓN (días)
1	Propuesta del proyecto y plan de trabajo	22 días
2	Introducción a las tecnologías implicadas	26 días
3	Desarrollo del código de clasificación	46 días
4	Recopilación de datos para el entrenamiento	20 días
5	Entrenamiento y testeo del sistema	45 días
6	Desarrollo de un video del producto	18 días
7	Redacción y defensa del Trabajo Fin de Grado	208 días

Seguidamente se desglosa cada paquete de trabajo en las tareas que lo componen, la descripción del mismo, las fechas de inicio y fin propuestas y reales y el resultado obtenido tras la realización del bloque de trabajo.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**Tabla 2.** Primer paquete de trabajo.

<b>Propuesta del proyecto y plan de trabajo</b>	1
Descripción del proyecto y organización. Diagrama de Gantt	<b>Fecha planeada de comienzo:</b> 30/11/15 <b>Fecha planeada de fin:</b> 29/12/15
	<b>Fecha real de comienzo:</b> 30/11/15 <b>Fecha real de fin:</b> 29/12/15
<b>T1:</b> Descripción y planificación del proyecto <b>T2:</b> Revisión y aprobación	<b>Resultado:</b> Plan de proyecto

**Tabla 3.** Segundo paquete de trabajo.

<b>Introducción a las tecnologías implicadas</b>	2
Lectura de artículos del estado del arte de rayos X de tórax e Inteligencia Artificial aplicada a la Visión por Ordenador tanto de forma independiente como de forma conjunta	<b>Fecha planeada de comienzo:</b> 29/12/15 <b>Fecha planeada de fin:</b> 02/02/16
	<b>Fecha real de comienzo:</b> 29/12/15 <b>Fecha real de fin:</b> 02/02/16
<b>T1:</b> Estudio del estado del arte de Machine Learning <b>T2:</b> Estudio del estado del art de Imagen Médica (rayos X de tórax)	<b>Resultado:</b> Situación en el marco del trabajo

**Tabla 4.** Tercer paquete de trabajo.

<b>Desarrollo del código de clasificación</b>	3
Decisión de qué framework y librerías se van a utilizar y análisis de las Redes Neuronales Convolucionales disponibles para decidir la arquitectura. Diseño de la CNN con el marco escogido.	<b>Fecha planeada de comienzo:</b> 01/02/16 <b>Fecha planeada de fin:</b> 04/04/16
	Fecha real de comienzo: 01/02/16 Fecha real de fin: 24/04/16
<b>T1:</b> Diseño de metodología de clasificación aplicada a la radiología <b>T2:</b> Implementación del código	<b>Resultado:</b> Código a implementar

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**Tabla 5.** Cuarto paquete de trabajo.

<b>Recopilación de datos para el entrenamiento</b>	4
Obtención, organización y puesta a punto de la base de datos necesaria para la implementación del código de clasificación	<b>Fecha planeada de comienzo:</b> 04/04/16 <b>Fecha planeada de fin:</b> 29/04/16
	<b>Fecha real de comienzo:</b> 24/04/16 <b>Fecha real de fin:</b> 15/05/16
<b>T1:</b> Búsqueda de bases de datos de imagen médica libres <b>T2:</b> Contacto con OpenI-Indiana University <b>T3:</b> Programación con Python para clasificar las imágenes disponibles según su código MeSH <b>T4:</b> Preparación de la base de datos para el entrenamiento	<b>Resultado:</b> Base de datos disponible para la implementación del código

**Tabla 6.** Quinto paquete de trabajo.

<b>Entrenamiento y testeo del sistema</b>	5
Implementación de la CNN. Entrenar la red con el conjunto de datos. Evaluar la red que se ha desarrollado.	<b>Fecha planeada de comienzo:</b> 02/05/16 <b>Fecha planeada de fin:</b> 01/07/16
	<b>Fecha real de comienzo:</b> 15/05/16 <b>Fecha real de fin:</b> 10/07/16
<b>T1:</b> Extracción de características usando red neuronal convolucional <b>T2:</b> Programación GUIDE en Matlab <b>T3:</b> Testeo del sistema con conjunto de datos de prueba	<b>Resultado:</b> Sistema de clasificación desarrollado y probado. Datos estadísticos del funcionamiento.

**Tabla 7.** Sexto paquete de trabajo.

<b>Desarrollo de un video del producto</b>	6
Diseño y desarrollo de un video en el que se pueda observar el potencial del sistema desarrollado.	<b>Fecha planeada de comienzo:</b> 28/07/16 <b>Fecha planeada de fin:</b> 21/08/16
	<b>Fecha real de comienzo:</b> 28/07/16 <b>Fecha real de fin:</b> 25/08/16
<b>T1:</b> Diseño del video <b>T2:</b> Desarrollo del video	<b>Resultado:</b> vídeo marketing del producto.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

Tabla 8. Séptimo paquete de trabajo.

<b>Redacción y defensa del Trabajo Fin de Grado</b>	7
Estructuración, organización y redacción del documento final del Trabajo de Fin de Grado así como la preparación y defensa del mismo.	<b>Fecha planeada de comienzo:</b> 30/11/15 <b>Fecha planeada de fin:</b> 15/09/16
	<b>Fecha real de comienzo:</b> 30/11/15 <b>Fecha real de fin:</b> 15/09/16
<b>T1:</b> Estructura de la memoria <b>T2:</b> Preparación del material necesario <b>T3:</b> Redacción de la memoria <b>T4:</b> Preparación de la defensa oral <b>T5:</b> Corrección de la memoria <b>T6:</b> Entrega de la memoria <b>T7:</b> Defensa oral del Trabajo Fin de Grado	<b>Resultado:</b> Memoria final del Trabajo Fin de Grado y defensa del mismo.

### 1.3.2. Diagrama de Gantt

Para poder realizar el diagrama de Gantt se ha hecho uso de la herramienta Project 2013. En la Figura 2, que aparece a continuación, se puede observar la distribución, organización y orden de los distintos paquetes de trabajo. A la izquierda se observa el nombre de mismos, junto con la duración destinada y las fechas de comienzo y fin de cada uno de ellos. A la derecha se puede apreciar la misma información pero de forma gráfica, mucho más visual.




Figura 2. Diagrama de Gantt del Trabajo Fin de Grado.

Cada uno de los paquetes de trabajo del diagrama de Gantt se puede desglosar en las tareas que lo componen, anteriormente detalladas. Es en el caso de la Figura 3, donde se observa que los paquetes de trabajo están ordenados y cada uno vinculado al siguiente (para poder empezar uno nuevo, se debe haber finalizado el anterior). Esto se cumple en los paquetes de trabajo del 1 al 6. El séptimo fue planificado para realizarse de forma simultánea a los otros 6, cubriendo todo el tiempo de duración destinado al proyecto, puesto que en la memoria se deben ir plasmando todos los pasos llevados a cabo.



“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

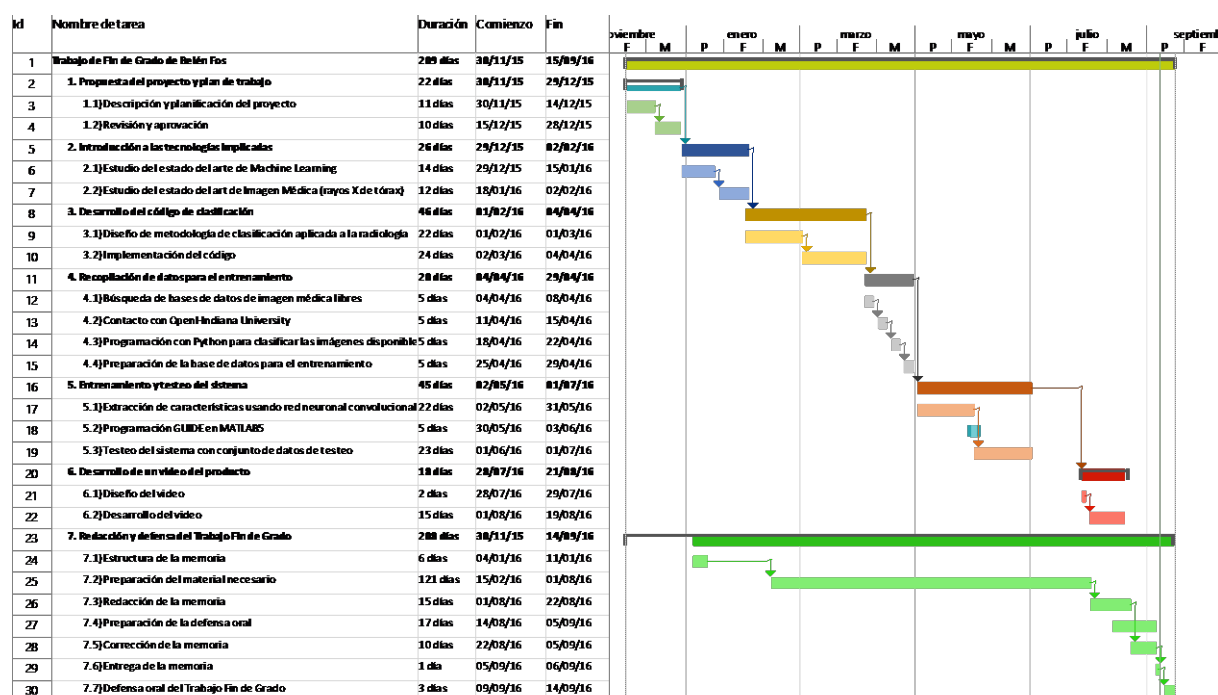


Figura 3. Diagrama de Gantt del Trabajo Fin de Grado desglosado.

Finalmente destacar que el proyecto completo tiene una duración de 209 días, con inicio el 30 de noviembre del 2015 y fin el 15 de septiembre del 2016.

### 1.3.3. Incidencias y modificaciones

#### a) En contenido

Inicialmente se pretendía realizar un clasificador de imágenes médicas de rayos X de tórax sanas y patológicas mediante el entrenamiento de una red neuronal desde 0. Sin embargo, tras una extensa revisión bibliográfica, se observó que entrenar una red neuronal convolucional profunda (CNN) desde 0 era difícil porque para ello se requiere una gran cantidad de datos de entrenamiento etiquetados y mucha experiencia en el campo para asegurar una correcta convergencia y evitar el sobreajuste. En el campo médico estos enormes conjuntos de datos (del orden de miles de millones de imágenes) no están disponibles, donde la anotación de los expertos es cara y las enfermedades presentes son escasas. Además las CNNs requieren una gran cantidad de recursos computacionales y de memoria, sin los cuales el proceso de entrenamiento sería extremadamente lento (Tajbakhsh et al, 2016).

En conclusión, deep learning desde 0 puede ser tedioso y consumir mucho tiempo, exigiendo una gran cantidad de diligencia, paciencia y experiencia.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Pese a que las diferencias entre imágenes naturales y médicas son considerables, alternativamente se decidió centrar el proyecto en la comprobación de si una CNN preentrenada en imágenes naturales era capaz de extraer de forma automática características relevantes de las imágenes médicas disponibles en nuestra base de datos (del orden de cientos o miles de imágenes, no millones) y usarlas para entrenar un clasificador de este tipo de imágenes, obteniendo resultados estadísticos relevantes en la validación del sistema de clasificación.

Finalmente, se decidió basar el proyecto en la idea de (Bar et al, 2015), en los que se examina la potencia de las redes neuronales convolucionales preentrenadas en imágenes no-médicas como extracción de características en radiografías de tórax.

En cuanto al sistema, no se pudo implementar en un ordenador personal por la ausencia de una GPU y las librerías complementarias requeridas por el sistema. Por este motivo se tuvo que implementar en un servidor del Grupo de Investigación Biomédica de Imagen (GIBI2<sup>30</sup>) habilitado para el proyecto y con una GPU NVIDIA Tesla k40 y los drivers necesarios instalados.

#### b) En organización

Los dos primeros paquetes de trabajo han sido iniciados y finalizados en las fechas establecidas en la planificación temporal. Sin embargo, el tercero se ha alargado ligeramente. La elección del marco a usar en el trabajo, las librerías empleadas y el desarrollo del código de clasificación son la parte más compleja de todo este Trabajo de Fin de Grado porque es un campo nuevo que se encuentra en una continua evolución exponencial. Las constantes novedades han alargado las decisiones y la finalización del mismo. Este pequeño retraso nos ha llevado a considerar ligeros cambios en las fechas de los siguientes.

Además, dos paquetes de trabajo que no habían sido considerados inicialmente han sido añadidos en el transcurso del proyecto. A continuación se detallan las tareas incluidas:

**Tabla 9.** Primer paquete de trabajo añadido.

<b>Abstract para EUSOMII/ESOI</b>	Primera extra
Surgió la oportunidad de redactar y enviar un abstract sobre el proyecto para hacer una comunicación oral en el congreso de EUSOMII/ESOI que se celebrará en Octubre en la Fe (Valencia)	Después de la 6
	<b>Fecha real de comienzo:</b> 11/07/16 <b>Fecha real de fin:</b> 18/07/16
T1: Elaboración del abstract. T2: Corrección del abstract. T3: Entrega del abstract.	<b>Resultado:</b> Abstract del proyecto enviado a EUSOMII/ESOI.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**Tabla 10.** Segundo paquete de trabajo añadido.

Implementación de mejoras en el código	Segunda extra
<p>Modificar y testear el algoritmo para conseguir mejoras en los resultados.</p>	<p>Después de la primera extra</p>
	<p><b>Fecha real de comienzo:</b> 18/07/16 <b>Fecha real de fin:</b> 28/07/16</p>
<p><b>T1:</b> Aplicación de mejoras en el sistema <b>T2:</b> Obtención de resultados estadísticos finales</p>	<p><b>Resultado:</b> Datos estadísticos finales del sistema</p>

Aun así, el retraso de las tareas no ha supuesto un problema de organización ya que se dejó un margen de tiempo considerable destinado solo a la elaboración de la memoria por si se producía el retraso de alguna de las tareas o la necesidad de añadir alguna nueva no prevista inicialmente.

## **CAPÍTULO 2. OBJETIVOS**

### **2.1. OBJETIVO GENERAL**

El objetivo general de este trabajo es el diseño del prototipo de un sistema que permita realizar de forma automática una primera tarea de screening en imágenes médicas, siendo capaz de separar las radiografías de tórax normales de las patológicas. Para ello se van a estudiar técnicas de inteligencia artificial (“machine learning” o “deep learning”) para la detección de alteraciones mediante adquisiciones de rayos X de tórax. Varias son las finalidades a las que podría destinarse el sistema propuesto, entre ellas:

- La detección de radiografías de tórax anormales de entre el abundante conjunto de radiografías no informadas de un hospital para ser revisadas e informadas de forma urgente, evitando así los posibles problemas médico-legales que la ausencia del informe radiológico conlleva.
- Mejorar la precisión y la eficiencia en los departamentos de radiología, usada como sistema de ayuda a la decisión en la lectura de imagen médica puesto que las radiografías de tórax presentan información potencial muy sutil, a veces inapreciable por el ojo humano.
- Cubrir de forma más económica la figura del radiólogo en los países del tercer mundo, donde ningún servicio de radiología sustancial está disponible debido a la falta de recursos económicos y de personal.

### **2.2. OBJETIVOS ESPECÍFICOS**

Además del objetivo general, para llevar a cabo el proyecto se han establecido los siguientes objetivos específicos:

- Estudio del potencial de las redes neuronales convolucionales en general y en la detección de patologías de tórax.
- Diseño e implementación de un sistema básico de screening de radiología de tórax anormal y patológica haciendo uso de redes neuronales convolucionales.
- Incorporación de otras tareas de screening:
  - Posible detección de algunas de las patologías más comunes en una imagen de rayos X de tórax anormal: cardiomegalia, opacidades, atelectasia, nódulo o efusión pleural.
- Diseño y programación de una interfaz gráfica de usuario con GUIDE de MATLAB que facilite el proceso.
- Obtención de resultados estadísticos que reflejan el rendimiento del sistema.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

- Comprobación del correcto funcionamiento del sistema implementado.
- Diseño y desarrollo de un video comercial que refleja el potencial que se puede alcanzar con el sistema.
- Presentación de un Abstract del proyecto en el primer congreso de ESOI/EUSOMII en el Hospital Universitario y Politécnico La Fe de Valencia y preparar la participación en el mismo, en caso de aceptación

Además, el Grado de Ingeniería Biomédica de la Universidad Politécnica de Valencia describe unas competencias generales y específicas a trabajar y desarrollar a lo largo de los cuatro años de carrera. Es por ello que, en el presente Trabajo Fin de Grado, como cierre de un periodo de formación, se ha profundizado en algunas de ellas, justificando los motivos del desarrollo del proyecto. Entre ellas, se han puesto en práctica algunas como:

- “Capacidad de proyectar, diseñar, desarrollar, instalar, utilizar y mantener procedimientos, dispositivos, equipos y sistemas para la prevención, diagnóstico, tratamiento y rehabilitación”.
- “Capacidad para el auto-aprendizaje, la consolidación y la actualización de nuevos conocimientos en el área de la ingeniería biomédica, y para emprender estudios posteriores con alto grado de autonomía”.
- “Capacidad para adquirir, analizar, interpretar y gestionar información”.

## **CAPÍTULO 3. ANTECEDENTES**

En este apartado se sitúa conceptualmente al lector en el marco en el que se va a trabajar, tanto desde el punto de vista médico como técnico, para que sea capaz de entender todo el desarrollo llevado a cabo en este trabajo. También se va a revisar ligeramente el estado del arte de todo lo que envuelve al proyecto.

### **3.1. ANTECEDENTES CLÍNICOS**

En antecedentes clínicos se va a estudiar cómo llegar a la radiografía de tórax y su posterior análisis para ser capaces de comprender las alteraciones en la misma. Para ello se va a partir desde conceptos más amplios cómo es el diagnóstico por la imagen, centrándonos en las técnicas basadas en rayos X y finalizando en la radiografía torácica.

#### **3.1.1. Diagnóstico por la imagen**

El diagnóstico por la imagen se basa en el uso de distintos principios físicos para visualizar la estructura interior, composición y funciones de los organismos vivos para que los profesionales médicos tengan evidencias disponibles para identificar lesiones en pacientes. Entre las distintas técnicas, podemos destacar las basadas en rayos X (incluyendo la radiografía convencional, radiografía por sustracción digital, tomografía computarizada, mamografía), las que se basan en resonancia magnética nuclear, las que se basan en la reflexión de los ultrasonidos (ecografía) o las que se basan en la emisión de radioisótopos (Fleckenstein and Tanum-Jensen, 2001).

A continuación vamos a centrarnos solamente en las técnicas basadas en rayos X, que es lo que presenta interés en este Trabajo Fin de Grado.

#### **3.1.2. Física de los rayos X.**

Los rayos X fueron descubiertos por Wilhelm Conrad Roentgen en el año 1895, uno de los físicos más importantes del siglo XIX. El motivo de su nombre fue que se trataba de una radiación desconocida en aquel momento con la posibilidad de penetrar en los cuerpos opacos. Al poco tiempo de ser descubiertos ya se usaban para fines médicos. Los rayos X son un tipo de radiación electromagnética al igual que la luz visible o las radiaciones ultravioleta e infrarroja. Aquello que caracteriza a los rayos X es su baja longitud de onda ( $10^{-10}$  m) y su alta energía. Es invisible a los ojos y atraviesa los objetos.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

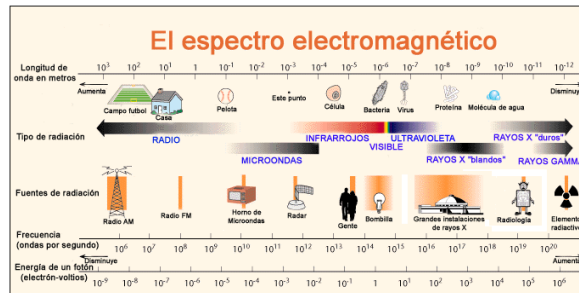


Figura 4. Espectro electromagnético extraído de en el que las radiaciones se agrupan según su radiación de onda, frecuencia y energía de un fotón.

Los fotones son cuantos de energía indivisible (del orden de los keV) mediante los cuales se transmiten los rayos X. No presentan masa. Esta unidad de energía E que transportan los fotones es directamente proporcional a la frecuencia e inversamente a la longitud de onda:

$$E = h\nu = \frac{hc}{\lambda} \quad (1)$$

donde  $h = 4.1357 \times 10^{-18} \text{ keV} \cdot \text{s}$  es la constante de Planck y  $c = 3.00 \times 10^8 \text{ m/s}$  es la velocidad de la luz. Para el caso del diagnóstico mediante rayos X, la energía fotónica se encuentra en el rango entre 20-200 keV.

Un tubo de rayos X funciona como un convertidor específico de energía, recibiendo la energía eléctrica y transformándola en otras dos formas de energía: radiación X (solo un 1% de los electrones) y calor (99%). El calor se considera como el producto indeseable de este proceso de conversión. La radiación X es el resultado de tomar la energía de los electrones y convertirla en fotones. Para ello los electrones se tienen que acelerar a través de un gradiente de campo eléctrico con un alto voltaje para llegar a chocar con la diana de metal, produciendo una desaceleración de los mismos. Este alto voltaje suele estar entre 10 kV y 100 kV junto con la intensidad de electrones, entre 10 y 50 mA, que se disparan del filamento, caracterizando la distribución de los rayos X del haz directo. El tubo donde tiene lugar esta conversión específica contiene dos elementos principales. Uno de ellos, el cátodo (-), es un filamento de tungsteno calentado con electricidad que proporciona la fuente de electrones. El otro es el ánodo (+), formado por una aleación de tungsteno, que actúa como objetivo de electrones, liberando emisión de rayos X característicos. La parte del ánodo donde chocan los electrones se denomina mancha focal. Este choque brusco produce una radiación electromagnética con un espectro continuo de energías entre 20 y 200keV, que es lo que se conoce como rayos X. Ambos elementos están contenidos en un envoltorio, normalmente de vidrio, que proporciona vacío, soporte y aislamiento eléctrico. El tubo presenta una ventana de Berilio que permite el paso de los rayos X, en forma de haz divergente. La forma y el tamaño de esta ventana pueden ser controlados mediante diafragmas que se ajustan, para determinar la apertura deseada. Este ajuste recibe el nombre de colimación.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

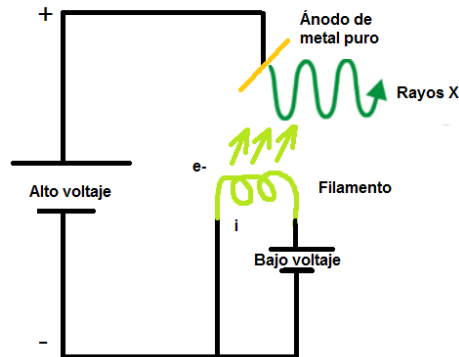


Figura 5. Tubo de rayos X.

La atenuación exponencial es el fundamento en que se basa la aplicación de los rayos X en la medicina. Estos rayos atraviesan ciertos materiales y en su camino pueden ser absorbidos o dispersados en su trayectoria, disminuyendo la intensidad original, dependiendo de la energía de los rayos X, la estructura y el grosor del material. (Rodríguez y Martínez, 2007). Esta reducción de intensidad se produce por un factor:

$$I = I_0 e^{-mx} \quad (2)$$

siendo  $m$  el coeficiente de atenuación lineal intrínseco de cada material. Tanto la absorción como la dispersión se deben a interacciones entre los fotones y los electrones del interior del átomo. Las interacciones más importantes en el intervalo de energías de interés en radiodiagnóstico son el efecto fotoeléctrico y la dispersión de Compton (Johns y Cunningham, 1983).

- El efecto fotoeléctrico → Es una forma de interacción de los rayos X o los fotones gamma con la materia. Un fotón de baja energía y alta velocidad interactúa con electrón del átomo (de una de las capas internas), arrancándolo. Este electrón pasa a llamarse fotoelectrón siendo el fotón absorbido durante el proceso. El hueco dejado por el electrón es reemplazado por otro electrón de las capas superficiales, generando un nuevo fotón de rayos X dirigido aleatoriamente y cuya energía depende del elemento. En este momento el átomo queda ionizado. La probabilidad del efecto es máxima cuando la energía del fotón incidente es igual o cuanto apenas mayor a la energía de enlace del electrón en su capa interna y el electrón está estrechamente ligado. Este efecto tiene lugar cuando la estructura tiene un número atómico elevado. Este efecto explica una de las razones de la atenuación del haz de rayos X a medida que pasa a través de la materia.
- El efecto Compton → Es la principal causa de la radiación dispersa en un material. Esto ocurre debido en la interacción de los rayos X o de fotones gamma con el electrón de valencia más exterior (y por tanto débilmente unido) a nivel atómico. El fotón incidente resultante se dispersa (cambia de dirección), así como expulsa el electrón (electrón de retroceso), que ioniza además otros átomos. Se trata de un proceso de absorción parcial



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

y donde el fotón original ha perdido la energía. Este efecto es directamente proporcional a la densidad física de la materia y al número de electrones de la capa exterior, inversamente proporcional a la energía del fotón (intermedia o alta, 70keV) y no depende del número atómico. En radiodiagnóstico este efecto abarca la mayor parte de la dispersión. Se debe evitar que los fotones interactúen con efecto Compton, porque la radiación dispersa produce borrosidad y pérdida de contraste en la radiografía.

- La difusión elástica → Se produce cuando la energía de los rayos X o gamma de los fotones es pequeña en relación a la energía de ionización del átomo, es decir, se produce con la radiación de baja energía. Al interactuar con el medio de atenuación, el fotón no tiene suficiente energía para liberar el electrón de su estado de enlace por lo que no se produce la transferencia de energía. El único cambio es un cambio de dirección (de dispersión) sin pérdida de energía del fotón. Este no es un proceso de interacción importante en radiografía con las energías que normalmente se usan, pues solo supone una parte de la dispersión total.

### **3.1.3. Rayos X en medicina**

Los rayos x en medicina se usan para generar imágenes de los tejidos y estructuras internas del cuerpo de manera no invasiva e informar al especialista.

Una radiografía convencional es una imagen en dos dimensiones de una estructura tridimensional, perdiendo toda la información sobre la profundidad. La información que proporciona la intensidad de los diferentes niveles de gris de la imagen hace referencia a la atenuación de los rayos X tras recorrer un camino del espacio tridimensional, indicando la densidad de los tejidos atravesados. Aquellas estructuras que presentan mayor densidad, como por ejemplo los huesos, aparecen de color blanco. Las zonas en las que hay aire se observan de color negro. Las diferentes tonalidades de gris del resto de estructuras van en función de la densidad de las mismas. La imagen resultante se observa a modo de negativo de la zona explorada. Esta diferencia de densidades es la que nos permite observar las distintas estructuras del cuerpo, puesto que áreas contiguas con densidades diferentes muestran una interfase entre ellas que las separa y las distingue.

Para obtener esta imagen, una máquina envía partículas de rayos X individuales (fuente emisora de radiación ionizante) que atraviesan el cuerpo anatómico. Una parte de estos rayos son absorbidos por los tejidos, pero otra parte de ellos suficiente debe penetrar para impactar en la película (detector de rayos X) o un ordenador. Entre 120-140 kVp (kilovoltaje moderadamente alto) permiten de forma adecuada la penetración en los tejidos pues produce un espectro de energías de rayos X mayor y más penetrante a la práctica estándar (50-70kV) (Ellis et al, 2006). Se forma una imagen que representa la "sombras" formadas por los objetos dentro del cuerpo. Las imágenes de rayos x que resultan de este proceso se llaman radiografías.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

### 3.1.4. Radiografía de tórax

El tórax es la parte superior del cuerpo situada entre el tronco y el abdomen que se constituye por la pared torácica (huesos, músculos, vasos y nervios) y la cavidad torácica que contiene la cavidad pleural y su contenido y el mediastino y su contenido.

Una de las exploraciones básicas con mayor realización en el departamento de radiodiagnóstico (sobre todo en Urgencias y en Atención Primaria) es la radiografía de tórax, obteniendo un alto rendimiento en pacientes sospechosos de presentar patología torácica, puesto que la mayoría de las enfermedades son expresadas en la imagen.

Habitualmente, cuando se lleva a cabo una radiografía de tórax se realizan dos radiografías con el paciente en bipedestación, en inspiración máxima y con la respiración suspendida. Una de ellas se trata de la proyección posteroanterior (PA) y la otra, la lateral izquierda (L). Normalmente las proyecciones PA y L serían suficientes. Sin embargo, en caso de duda en el diagnóstico, antes de acudir a técnicas de alta tecnología se puede recurrir a otras proyecciones complementarias que pueden ayudar a resolver o confirmar el diagnóstico. Entre ellas destacamos las oblicuas, las realizadas con bajo kilovoltaje (60-80 kVp), las lordóticas, las proyecciones en decúbito supino o lateral con rayo horizontal y las llevadas a cabo en espiración (Bayo et al, 2005).


Para dar por válida una radiografía de tórax y con buena **calidad** nos debemos fijar en la penetración, la inspiración, el contraste, el centrado y la definición (Vargas, 2013).

- Para que la penetración sea la adecuada debe estar realizada con un alto kilovoltaje, observándose la totalidad de las vértebras y las costillas a través del corazón, con el motivo de observar las consolidaciones retrocardíacas.
- El paciente debe estar en inspiración máxima y apnea, visualizándose en la imagen por lo menos 6 arcos costales anteriores por encima de las cúpulas diafragmáticas y entre 8 y 9 arcos costales posteriores sobre el parénquima pulmonar.
- En cuanto al contraste, se deben apreciar las estructuras que presentan densidades distintas (esqueleto, pulmones y partes blandas).
- El paciente debe estar de frente, equidistando los extremos internos de la clavícula de las apófisis espinosas vertebrales, consiguiendo así un buen centrado de la imagen.
- La total quietud del paciente durante la prueba proporciona una buena definición de la imagen.

Tras comprobar una buena calidad de la imagen se deben revisar las partes blandas y óseas, la silueta cardio-mediastínica, los hilos pulmonares, el diafragma y los senos costofrénicos, el parénquima pulmonar, las estructuras extratorácicas (cabeza, cuello y abdomen) y si se dan artefactos en la imagen para comprobar si se trata de una radiografía torácica sana o patológica.

Seguidamente se va a analizar cómo se verían las distintas estructuras presentes en la radiografía de tórax posteroanterior en caso de ser normales.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



**Figura 6.** Radiografía PA de tórax normal en la que se observan las distintas estructuras a observar por el radiólogo.

Paredes del tórax:

- **Huesos** → Múltiples estructuras óseas visibles de color blanco en la radiografía de tórax. Se deben visualizar las costillas, el esternón, las escápulas y la columna dorsal (incluyendo la apófisis espinosa). Prestar atención a su integridad, densidades y a su simetría. En cuanto a las costillas, los arcos posteriores se presentan un poco superiores a lo anteriores, pudiéndose ver en toda su longitud. Los espacios entre costillas a ambos lados del tórax suelen ser iguales, y los bordes, más o menos paralelos. En adultos o ancianos, es posible confundir los cartílagos costales calcificados con lesiones patológicas del pulmón. La densidad de la columna vertebral disminuye al bajar, perdiéndose detrás del corazón. Se pueden observar los cuerpos vertebrales borrosos y las apófisis espinosas en la línea media. Del esternón solo se veía la zona del manubrio. En cuanto a las escápulas son desplazadas fuera del campo de proyección de los pulmones aunque puede que se vea su borde interno, proyectándose sobre estos.
- **Diafragma** → Pared musculotendinosa límite que separa el tórax de la cavidad abdominal. Es el principal músculo inspiratorio. Tres agujeros en este órgano permiten el paso de la aorta, el esófago y la vena cava inferior. En la radiografía se observa dividido en dos porciones. La parte derecha recubre el hígado y la izquierda (más baja por la presencia del ventrículo izquierdo) el estómago y el bazo, ambas presentando una estructura redondeada.

Cavidad torácica:

- **Tráquea** → Estructura en forma de tubo de 6 a 9 cm que baja por la línea media. En una radiografía de tórax PA se puede ver como una especie de columna oscura (densidad aire sobre

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

la densidad agua del ediastino) y bien definida en sus bordes, ligeramente desviada hacia la derecha debido al cayado aórtico. El diámetro transversal normal suele estar entre 1 y 3 cm.

- **Bronquios principales** → El sistema de bronquios se ramifica asimétricamente, siendo el izquierdo (con dos bronquios lobares) más largo y horizontal que el derecho (con tres bronquios lobares). Ambos se observan en PA
- **Mediastino** → Se encuentra en la parte central del tórax, al medio de los sacos pleurales de los pulmones, debajo de la base del cuello y encima del diafragma. En la radiografía de tórax se observa como una estructura opaca en la que no se pueden diferenciar las partes que lo componen. Este se debe a que la mayoría de estas estructuras presenta densidad agua, formando una silueta conjunta que impide ver los límites entre ellas. Solamente se pueden ver la tráquea y los bronquios principales porque presentan densidad aire frente al resto. En el mediastino se encuentra el corazón, la arteria aorta, las venas cavas, las arterias y venas pulmonares, la tráquea, los bronquios principales, el esófago y ganglios linfáticos y nerviosos.
- **Parénquima pulmonar** → Prestar especial atención desde el vértice pulmonar hasta su base, y los vasos pulmonares desde los hilios hacia los extremos.
- **Hilios pulmonares** → Zona por donde las venas, arterias, bronquios, nervios y ganglios linfáticos se dirigen del mediastino a los pulmones. En la imagen radiológica solamente se pueden apreciar las arterias y las venas pulmonares puesto que los bronquios presentan densidad aire y no se observa nada y el resto son muy pequeños para visualizarse. Se presentan dos hilios (derecho e izquierdo) de misma grandaria y densidad, encontrándose el izquierdo por encima del derecho.
- **Pleuras** → Membrana serosa que recubre la caja torácica, la pleura parietal, los pulmones y la pleura visceral. El espacio pleural es virtual y normalmente esta no es visible en una radiografía de tórax simple. Sin embargo hay que prestar especial atención a las cisuras pleurales.


### 3.1.5. Patologías de interés en el proyecto

A continuación se lleva a cabo una breve explicación de las patologías que se han tenido en cuenta en este proyecto (las más predominantes en la base de datos disponible) para poner al lector en situación y poder comprender las diferencias entre radiografías normales y anormales.

- a) **Atelectasia o colapso** → Pérdida de volumen de un segmento o todo el pulmón con aumento de su densidad en la radiografía, debida a una disminución de la cantidad de aire en el alveolo. (Vargas, 2013). Es muy importante detectar la presencia de esta patología puesto que en muchos casos es uno de los primeros signos de cáncer de pulmón.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Se observan una especie tractos fibrosos con patrón alvéolo que tiran del mediastino hacia el exterior. En el caso de presencia de esta patología se desplazan las cisuras interlobares, se observan vasos de opacidad oscura y bien definidos sin broncograma aéreo, aumenta la densidad del pulmón afectado disminuyendo el volumen, se desplazan las estructuras mediastinales (corazón y tráquea), elevación diafragmática, hiperinsuflación compensadora y aproximación de las costillas. La etiología más común es por obstrucción de un bronquio principal.



**Figura 7.** A la izquierda, radiografía de tórax normal. A la derecha, radiografía PA del tórax con atelectasia, mostrando un colapso del lóbulo superior izquierdo, una opacidad apical izquierda y un desplazamiento anterior de la cisura mayor.

**b) Cardiomegalia** → Agrandamiento anormal de la musculatura cardíaca como signo en personas que pueden padecer insuficiencia cardíaca sistólica crónica o miocardiopatías, afectando a un ventrículo o a los dos.

Una de las observaciones más fáciles para detectar cardiomegalia es fijarse en el ratio cardiotorácico, que es la división entre el diámetro más ancho del corazón y el diámetro interior más ancho de la caja torácica. Esta relación debe ser menor del 50%, en la mayoría de la gente normal. Si esta es mayor del 50%, es posible que se presente cardiomegalia. Aunque hay casos que el corazón es normal pero esta relación es mayor del 50%. Estas causas extra cardíacas podrían ser obesidad, embarazo y ascitis (los pacientes no pueden estar en completa inspiración, están en espiración, y el corazón parece más grande de lo normal), derrame pericárdico, síndrome de la espalda recta, anomalías de la pared torácica (pectus excavatum, xifosis), películas AP portátiles o rotación del paciente (izquierda) (De Pablo, 2003).

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

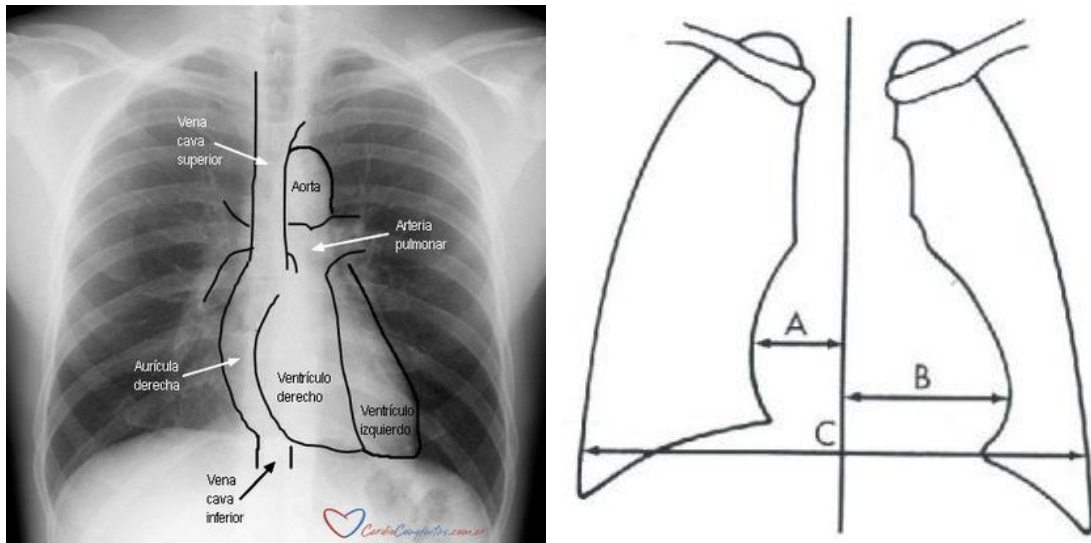


Figura 8. Anatomía cardíaca básica en radiología de tórax y relación cardiotorácica.

La medición de la relación cardiotorácica se obtiene de la siguiente forma:

$$\frac{A+B}{C} \quad (3)$$





Figura 9. A la izquierda, radiografía de tórax normal, donde su ratio cardiotorácico es menor del 50%. A la derecha, radiografía con cardiomegalia, donde la relación supera el 50%.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

- c) **Efusión o derrame pleural.** Acumulación anormal y excesiva de líquido entre las capas de tejido (pleura) que recubren los pulmones y la cavidad torácica. Las causas son múltiples, destacando la insuficiencia cardíaca, enfermedades inflamatorias, infecciosas, tumorales, traumáticas y vasculares (Fraser y Paré, 2002).


Los derrames pleurales aparecen en las radiografías de tórax como un espacio en blanco en la base del pulmón. Se observa un emborronamiento en el ángulo costofrénico, un aumento de la densidad u homogeneización sobreimpuesta pulmonar, una disminución de la claridad del contorno de la silueta hemidiafragmática, una disminución de la visibilidad de la vasculatura lobar inferior y una acentuación de la cisura menor.



**Figura 10.** A la izquierda, derrame pleural subpulmonar derecho. Al centro, derrame pleural izquierdo. A la derecha, derrame pleural de gran magnitud.

- d) **Nódulos pulmonares.** Un nódulo pulmonar solitario se define como una opacidad discreta y bien delimitada de menos o igual a 3 centímetros de diámetro. Debe estar completamente rodeada de parénquima pulmonar, no toca el hilio o el mediastino y no está asociado con adenopatía, atelectasia o derrame pleural. El diagnóstico diferencial es el mismo que el de una masa excepto que la probabilidad de malignidad aumente con el tamaño de la lesión. Las lesiones menores de 3 cm son más comúnmente granulomas benignos mientras que las lesiones mayores de 3 cm se tratan de malignas hasta que se demuestre lo contrario y se denominan masas. Si aparecen múltiples masas pueden deberse a neoplasias, infección, inflamación, causas vasculares o inhalación, aunque generalmente se debe a metástasis.

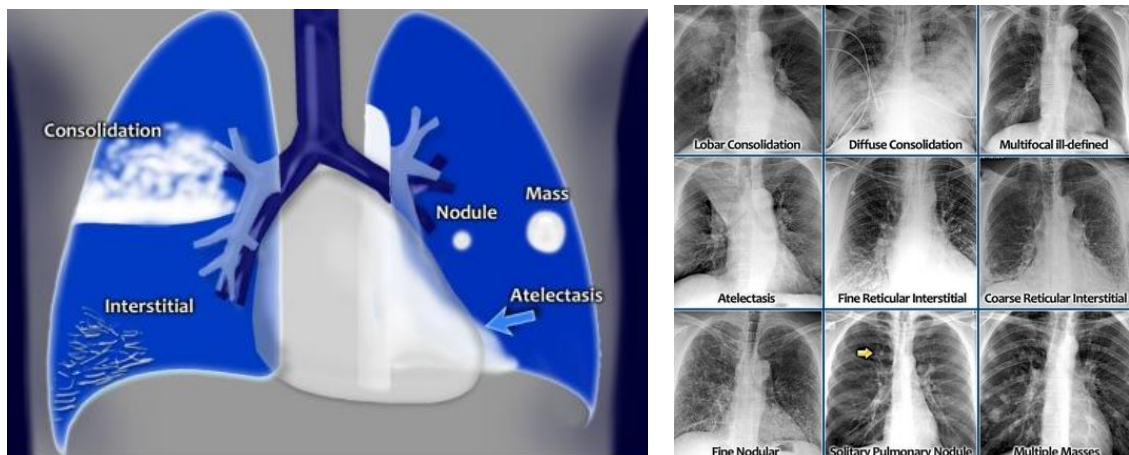
*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



**Figura 11.** A la izquierda y a la derecha, presencia de un nódulo pulmonar solitario derecho. En el centro, radiografía con múltiples nódulos.

- e) **Opacidades** → Anormalidades pulmonares con un aumento de densidad. Debido a este aumento, se van a apreciar zonas más blancas en la luz de los pulmones, que deberían estar oscura por la presencia del aire. Estas se pueden dividir en consolidaciones, intersticiales, nódulos o masas y atelectasia (agrupación de todas las patologías previamente detalladas).

Las consolidaciones son cualquier proceso patológico que llena los alvéolos con líquido, pus, sangre, células (incluyendo células tumorales) u otras sustancias que resultando en lobar, difusa u opacidades multifocales mal definidas. Las lesiones intersticiales implican el tejido de soporte del parénquima pulmonar que resulta en opacidades reticulares finas, gruesas o pequeños nódulos.



**Figura 12.** Ejemplos más comunes de opacidad en radiografía de tórax.



“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

### 3.1.6. Digitalización de la radiografía de tórax.

Debido al coste de la película convencional en radiografía, el gran espacio físico necesario para almacenar la gran cantidad de imágenes, el transporte y el deterioro de las mismas, esta técnica está evolucionando hacia la digitalización. Esta evolución en la técnica permite una mayor rapidez en la adquisición y envío de las radiografías a través del sistema informático, una calidad superior de las mismas con muy buena resolución de contraste y la posibilidad de almacenamiento y manipulación en el ordenador (Bayo et al, 2005). \_En la digitalización se usa o bien una placa de almacenamiento de fósforo que es leída por un láser después de la exposición o convirtiendo los rayos X incididos directamente en una señal eléctrica.

Uno de los primeros proyectos en la detección de patologías en radiografías de tórax digitales fue el que llevaron a cabo Carrillo-de-Gea et al, 2010 usando la técnica de Local Binary Patterns (LBP) (Ojala et al, 1996). Otra técnica que también se usó en la separación entre casos patológicos y sanos fue Bag-of-Visual-Words (BoVW) (Csurka et al, 2004), en estudios como los llevados a cabo por (Avni et al, 2011; Avni, Konen et al, 2011). En todas estas investigaciones, seguían el método de extraer características de bajo nivel de las imágenes médicas de forma manual.

### 3.2. ANTECEDENTES TÉCNICOS

El **machine learning** o aprendizaje automático es un tipo de inteligencia artificial que dota a los ordenadores de la habilidad de aprender y llevar a cabo tareas determinadas sin haber sido explícitamente programados para ello. Cada vez más investigadores lo ven como el camino idóneo para alcanzar una inteligencia artificial a nivel humano.

Considerando una tarea de clasificación de una imagen en distintas categorías, si se realiza una aproximación tradicional el primer paso sería una extracción manual de características de la imagen (ejes, distribución de colores...). Estas técnicas no funcionan demasiado bien cuando se aplican directamente a las imágenes puesto que no se conoce la estructura completa y la composición natural de las mismas. El siguiente paso sería la clasificación de las imágenes de entrada, entrenando un clasificador con los vectores compactos de características de bajo nivel extraídas de forma manual.

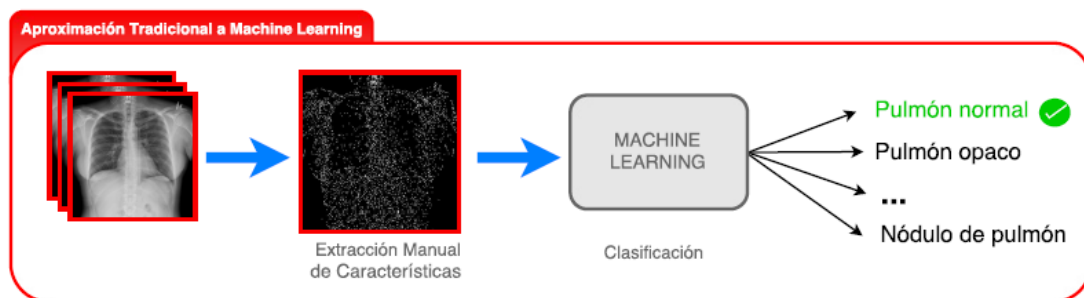


Figura 13. Aproximación tradicional de machine learning o también llamada ‘shadow learning’.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

Actualmente ha surgido una nueva tendencia de extraer estas características mediante el uso de **deep learning**, una técnica de *machine learning* que puede aprender representaciones útiles directamente de datos como imágenes, texto y audio. Estas características son de naturalezas distintas (texturas, colores, ejes u otras más específicas)

En una clasificación de imágenes mediante técnicas de *deep learning*, como es el caso de una **red neuronal convolucional (CNN)**, el algoritmo aprende estas características de las imágenes de forma automática generando representaciones de bajo nivel en capas primeras de la red neuronal convolucional como ejes y esquinas a representaciones más específicas del problema en capas más superiores. Es aquí donde se introduce la diferencia, puesto que los algoritmos de deep learning llevan a cabo de forma natural el aprendizaje de principio a fin. Esto significa que las capas de la red neuronal convolucional llevan a cabo el proceso tanto de extracción de representaciones como de clasificación (última capa de la red neuronal).

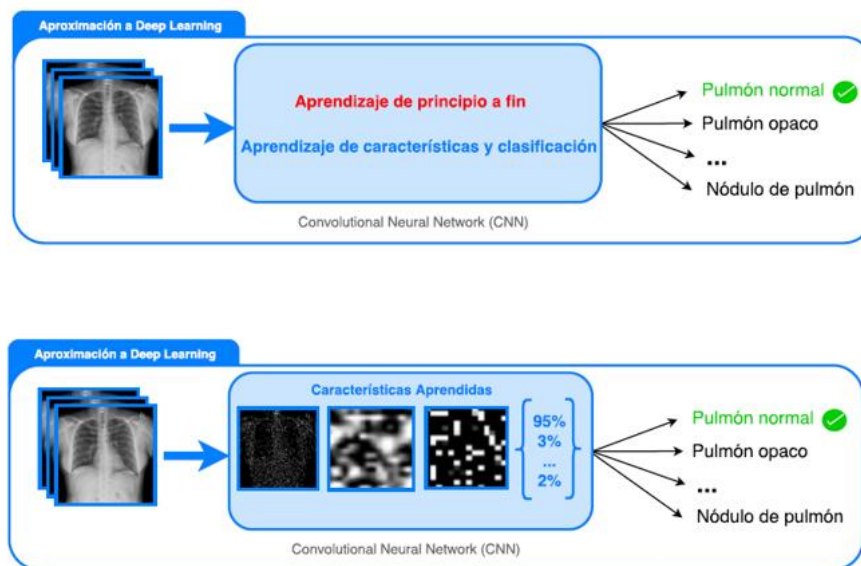


Figura 14. Aproximación de deep learning en la clasificación de imágenes. Extracción de características y clasificación automática mediante un sistema de caja negra.

Dos caminos son posibles a la hora de usar las CNNs en reconocimiento visual por ordenador.

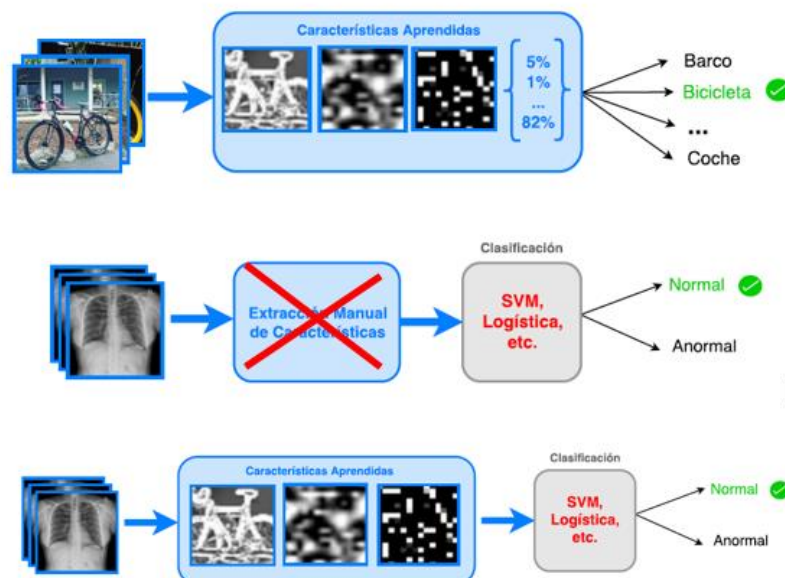
Una opción es entrenar una red neuronal desde 0, lo que implicaría disponer de miles de millones de imágenes de entrenamiento. Estas se usarían para aprender los pesos necesarios para que, de forma automática, la red sea capaz de reconocer una imagen no usada en el entrenamiento. Sin embargo este procedimiento requiere un conocimiento profundo en el campo, para poder escoger los parámetros e hiperparámetros que no conduzcan a un sobreajuste. Este camino podría llevar días, o incluso semanas de entrenamiento.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Otra alternativa sería utilizar una red neuronal convolucional como extractor de características, recomendable en conjuntos no muy extensos de imágenes de entrenamiento (de cientos a miles). En la literatura, a este caso se le suele denominar transferencia de conocimiento de un problema a otro. La **transferencia de conocimiento** se define como la habilidad de un sistema a reconocer y aplicar conocimiento y habilidades aprendidas en tareas previas en una tarea nueva. Estudios como (Pan y Yang, 2010; Zeiler y Fergus, 2013; Oquab et al, 2014) han puesto en evidencia la efectividad de esta técnica en tareas de reconocimiento visual. En nuestro proyecto vamos a transferir representaciones aprendidas de otro dominio para detectar pulmones normales y anormales.

En otras palabras podríamos definir la transferencia de conocimiento como el hecho de enseñar a una persona a detectar diferencias entre objetos. Si se la enseña a partir de muchos ejemplos a fijarse en las formas, colores, organización de los mismos... cuando ya lo ha aprendido, es capaz de hacerlo para otros tipos de imágenes nuevas y diferenciarlas.

La extracción de características es el proceso de obtener información discriminante de una imagen en una forma reducida normalmente conocida como vector de características. Una CNN bien entrenada puede servir como extractor de características. Se puede tomar un modelo CNN entrenado en un problema distinto, donde la CNN puede aprender a reconocer objetos determinados que no coinciden con los que nosotros queremos clasificar. Se puede usar este modelo como extractor de características internamente de una forma composicional para nuestra tarea en concreto, y luego usar estas características para entrenar un clasificador de imágenes.



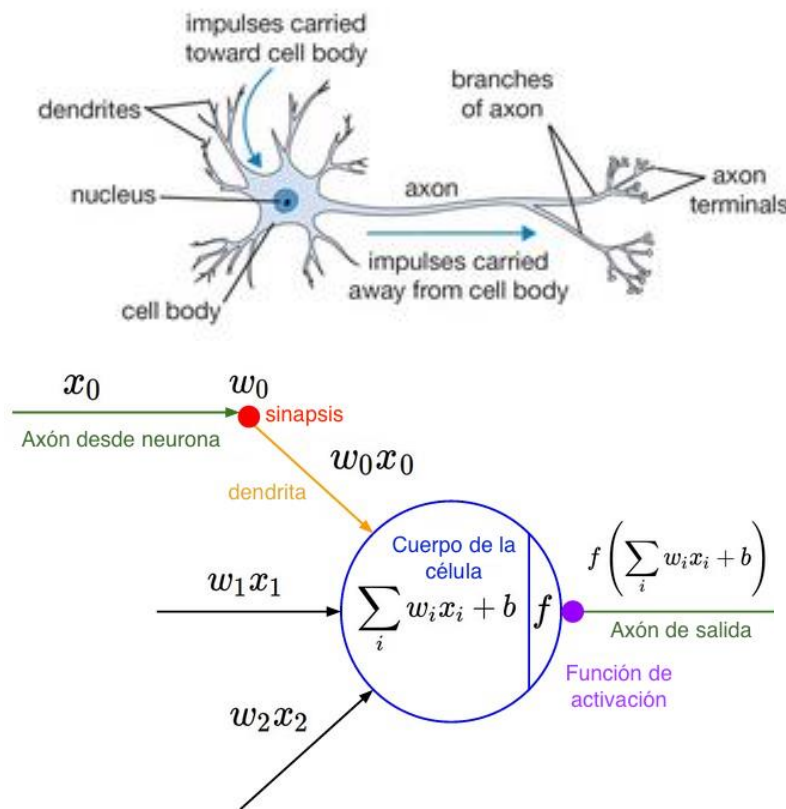
**Figura 15.** CNN entrenada para una reconocer clases como barco, bicicleta, coche... Para nuestra tarea en concreto, en lugar de extraer características de forma manual, se transfiere el conocimiento de la CNN entrenada. Extrae internamente características de las clases de la nueva tarea de reconocimiento que se usarán para entrenar un clasificador.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

Debido a la existencia de numerosas variedades de CNNs y al avance en la computación en paralelo para GPUs modernas, el deep learning ha conseguido un interés especial y con él, el uso de las redes neuronales convolucionales.

Se va a llevar a cabo una breve descripción de las redes neuronales y en concreto de las convolucionales para poder comprender mejor los conceptos del desarrollo con conceptos extraídos de *CS231n Convolutional Neural Networks for Visual Recognition*.

Las **redes neuronales** son algoritmos de entrenamiento de *machine learning* que explotan múltiples capas de procesamiento de información no lineal para análisis patrones y clasificación, siendo inspiradas en cómo trabaja el cerebro humano. Las neuronas son las unidades de computación y cada neurona lleva a cabo un producto escalar con la entrada y sus pesos, luego añade el sesgo y aplica la función de activación (no linealidad). Se puede observar en la Figura 16.



**Figura 16.** Analogía del funcionamiento de una neurona en la Red Neuronal con una neurona del cerebro humano. El funcionamiento en la neurona es igual en las redes neuronales y en las convolucionales.

El sistema nervioso de una persona contiene alrededor de 86 billones de neuronas conectadas con  $10^{15}$  sinapsis. De las dendritas se envía una señal de entrada a la neurona que generará señales de salida a través de su axón. Cabe la posibilidad de ramificación del axón y mediante sinapsis, que se

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

conecte con las dendritas de otras neuronas. Como vemos en el modelo matemático análogo a la neurona humana de la Figura 16, las señales ( $x_0$ ) que viajan por el axón interactúan con las dendritas de otras neuronas ( $w_0x_0$ ) por sinapsis ( $w_0$ ). Estos pesos que representan las fuerzas sinápticas se pueden aprender y controlan la influencia (pesos positivos) o inhibición (pesos negativos) entre neuronas. En el modelo humano, a través de las dendritas se envían señales a la neurona, donde todas se suman. Si se sobrepasa un umbral, la neurona se activa y manda un impulso a través de su axón. Matemáticamente no importan los tiempos de impulsos aunque si la frecuencia de activación. Esta activación biológica se traduce en una función (función sigmoide,  $\sigma$ ) que representa la frecuencia de los impulsos a lo largo del axón, que toma valores entre 0 y 1 tras recibir una señal de entrada real.


Sin contar con las neuronas de la capa de entrada, cada neurona  $x_i$  de la red toma como entrada los valores de las neuronas de la capa precedente que alimentan a  $x_i$ . Por tanto la entrada a una red neuronal calculada como la combinación lineal ponderada de sus entradas sería:

$$a_i = \sum_i w_i x_i + b \quad (4)$$

El término  $b$  es un sesgo asociado a la neurona. A esta  $a_i$  (entrada a una red neuronal) se le aplica una función de activación no lineal. Esta función de activación de una neurona sería:

$$z_i = f(a_i) = f(\sum_i w_i x_i + b) \quad (5)$$

Para aprender a través de la red y propagarse la información (forward propagation), una vez se toman los valores de entrada, la primera capa convolucional obtiene las activaciones, que solo dependen de los valores de las neuronas de las capas anteriores. Al final del proceso se obtiene un conjunto de salida y en función de las entrada  $x$  recibidas. Esta salida se usará para la clasificación de su entrada  $x$ .



**Figura 17.** Red neuronal simple de tres capas.

Como se observa en la Figura 17, una red neuronal recibe una entrada ( $x$ ) en forma de un único vector y lo transforma a través de una serie de capas ocultas. Cada una de estas se compone de una serie de neuronas, totalmente conectadas a todas las neuronas en la capa anterior, calculando una función dependiente de los valores de cada neurona de la capa de entrada. Las neuronas de una misma

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*


capa no están conectadas entre sí. La última capa es la capa de salida y en clasificación esta representa la puntuación de clase. La arquitectura de red es el patrón de conectividad de una red.

En el caso de que las **entradas** sean **imágenes** completas, es decir, entradas de alta dimensión, las redes neuronales no funcionan bien puesto que la conectividad total de las neuronas de una capa con las de la siguiente es un desperdicio (dejando sin aprovechar la estructura de la imagen, por ejemplo, los píxeles adyacentes de una imagen tienden a estar muy correlados mientras que los que están separados no), y el gran número de parámetros conduciría a un sobreajuste. En este caso se usan las redes neuronales convolucionales. Estas últimas suponen explícitamente que las entradas son imágenes, lo que permite codificar ciertas propiedades de las mismas en la arquitectura, haciendo la función hacia adelante más eficiente de implementar y reduciendo de forma considerable los parámetros de la red.

Una **red neuronal convolucional** (CNN o Convnet) es una poderosa técnica de *deep learning*. El procedimiento es similar a la Red Neuronal ordinaria explicado anteriormente. Básicamente se definiría como una secuencia de múltiples capas de características. Cada capa transforma un volumen de entrada 3D en un volumen de salida 3D, a través de funciones diferenciables que pueden tener o no tener parámetros. Las capas de la red se constituyen de neuronas dispuestas en tres dimensiones (anchura, altura y profundidad) que tienen pesos y sesgos que se pueden aprender. Cada neurona recibe entradas, lleva a cabo un producto escalar (entre la entrada y el peso) y a veces puede seguirse con una no linealidad.

En este caso las neuronas de una capa solo están conectadas a una pequeña región de la capa anterior. La extensión espacial de esta conectividad es un hiperparámetro llamado **campo receptivo** de la neurona, que sería lo mismo que **tamaño del filtro**. La extensión de la conectividad a lo largo del eje de profundidad es siempre igual a la profundidad del volumen de entrada. Las conexiones son locales en el espacio (a lo largo de la anchura y altura), pero siempre completas a lo largo de toda la profundidad del volumen de entrada.

Al final de la red se reduce la imagen completa a un único vector de puntuación de clase, que es la salida.



**Figura 18.** Funcionamiento de una red neuronal convolucional. La capa de entrada roja es la imagen, siendo la altura y la anchura las dimensiones de la imagen y la profundidad, los tres canales de color (rojo, verde, azul).

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---


Hay cinco capas principales que se apilan para construir arquitecturas de redes neuronales convolucionales completas, transformando los valores de los píxeles de la imagen original a una puntuaciones de clase finales. Las capas pueden ser:

- Entrada → Mantiene los valores de los píxeles de la imagen de entrada (el alto, el ancho y los tres canales de color).
- Convolucionales → Es el bloque central de construcción de la red. Sus parámetros consisten en un conjunto de filtros que se pueden aprender. Estos filtros son pequeños espacialmente (ancho y largo) pero se extienden a lo largo de toda la profundidad del volumen de entrada. La ConvNet aprenderá los filtros que se activan cuando algún tipo de características específicas se detectan en la entrada. Esta capa calcula la salida de las neuronas conectadas a regiones locales en la entrada, siendo cada cálculo un producto escalar entre los pesos y la pequeña región a la que se conectan del volumen de entrada.
- Pooling o submuestreo → Esta capa reduce el tamaño espacial de la entrada para disminuir el número de parámetros reduciendo las respuestas convolucionales, disminuir la computación en la ConvNet y proporcionar un grado de invarianza translacional al modelo. Para ello se lleva a cabo una operación de reducción de muestreo a lo largo de las dimensiones espaciales (ancho y alto). Se toman las respuestas convolucionales y se dividen en x-y bloques. Tras aplicarle el pooling a estas respuestas nos vamos a quedar con un mapa de x-y respuestas, cada una representativa de un bloque tomando de cada uno de estos bloques se toma el mayor valor (max pooling) o el promedio (mean pooling)
- Totalmente conectadas → Neuronas entre dos capas adyacentes están todas conectadas por parejas, mientras las neuronas de la misma capa no. Pueden ser interpretadas como capas convolucionales de 1x1. Estas capas calcularán la puntuación de clase.
- ReLU (no linealidad) → Esta capa calcula la función de  $f(x) = \max(0, x)$ , que umbraliza en 0. Esta capa mantiene el tamaño del volumen sin cambios.

Las capas convolucional y totalmente conectada llevan a cabo transformaciones que son función de la activación en la entrada y de los parámetros de estas capas: pesos y sesgos de las neuronas. Estos parámetros se entrenan con descenso de gradiente de modo que las puntuaciones de clase que la CNN calcula son consistentes con las etiquetas en el conjunto de entrenamiento para cada imagen.

Las capas ReLU y pool implementan una función fija, no presentando parámetros.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



**Figura 19.** Funcionamiento de una imagen de 32x32 con la primera capa convolucional.

En la Figura se puede observar un ejemplo de imagen (rojo) de 32x32 (ancho x alto) y tres canales de color (profundidad). En azul tenemos la primera capa convolucional compuesta por un volumen de neuronas. Cada neurona en la capa convolucional se conecta con una región local de la imagen de entrada, pero toda la profundidad de la misma. Hay 5 neuronas en la profundidad de esta capa, todas mirando hacia la misma dirección de la imagen.

En las redes neuronales estándares la neurona obtenía una combinación lineal de sus entradas por los pesos. Esto se podía comprender como la evaluación de un filtro lineal sobre los valores de la entrada. Ahora, con las redes neuronales convolucionales hay varias neuronas de la misma capa convolucional que intercambian pesos lo que significaría la evaluación del mismo filtro sobre varias subventanas de la imagen de entrada. De este modo la red neuronal convolucional podría entenderse como el aprendizaje más efectivo a un conjunto de filtros. Que la red pueda aprender una codificación general se podría conseguir o características de los datos de entrada se podría conseguir haciendo uso del mismo conjunto de filtros sobre la imagen entera. Con el objetivo de conseguir una generalización de la CNN se restringen los pesos a ser iguales a través de diferentes neuronas teniendo así un efecto de normalización sobre la CNN (Herrera, 2015).

Recientemente se han llevado a cabo estudios de reconocimiento de imágenes mediante la extracción de características genéricas haciendo uso de las CNNs. Entre ellos podemos destacar los llevados a cabo por Razavian et al. (2014) y Oquab et al. (2014). Estas investigaciones demuestran que se trata de un método tecnológico que se encuentra en cabeza.

Estas técnicas no solo se usan para reconocimiento visual en general, pues ya han sido aplicadas a muchos proyectos en el campo de la medicina. Los primeros estudios que usaron técnicas de deep learning para conseguir resultados médicos fueron los llevados a cabo por Ciregan et al. (2013) y por Prason et al. (2013). Sin embargo, la cosa ha ido más allá y recientes publicaciones vinculan la inteligencia artificial y en concreto, el deep learning con la medicina, demostrándonos que es un frente



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

abierto en el que queda aún mucho por explorar. Algunos de estos estudios más recientes han sido realizados por Tajbakhsh et al. (2016), Shin et al. (2016) o Shin, Holger et al. (2016) entre otros.

*Transfer Representation Learning for Medical Image Analysis, Convolutional neural Network for Medical Clustering, Off-the-shelf convolutional neural network features for pulmonary nodule detection in computed tomography scans, Convolutional neural networks for mamography mass lesion classification* también podrían añadirse al grupo de investigaciones que apuestan fuerte por la innovación en el campo de la medicina, aplicando la inteligencia artificial en el diagnóstico por imagen.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

## CAPÍTULO 4. MATERIAL Y MÉTODOS

En este capítulo se van a describir los pasos que se han seguido para llegar a alcanzar el objetivo final de este Trabajo Fin de Grado: determinar si se trata de una radiografía de tórax normal o anormal (con varias patologías posibles) y etiquetar la imagen correctamente. En la Figura podemos encontrar el flujo de trabajo con los tres pasos principales que se detallarán a continuación:



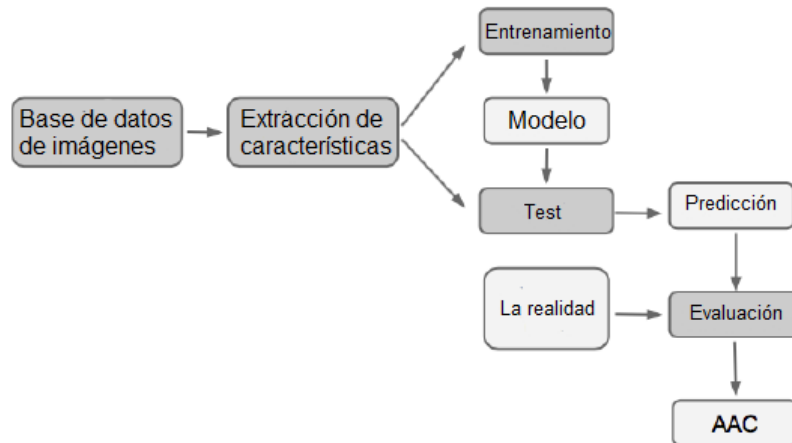
Figura 20. Flujo de trabajo seguido en el desarrollo experimental.

- 1) Preparación de la base de datos: obtención, organización y estructuración de la misma.
- 2) Extracción automática de características de cada una de las categorías mediante el uso de una red neuronal convolucional.
- 3) Entrenamiento, con las características extraídas, de un clasificador binario capaz de clasificar una nueva imagen perteneciente a una de las dos categorías previamente establecidas.

El diseño planteado es una combinación entre el *machine learning* tradicional y la clasificación de principio a fin usando una CNN. En este caso no se extraen características de forma manual como en el *machine learning* tradicional sino que se hacen de forma automática haciendo uso de la CNN preentrenada, y estas se usan para entrenar un clasificador binario, como sí ocurre en *machine learning* supervisado.

Un flujo de trabajo resumen de lo que se va a llevar a cabo de forma experimental en este proyecto es el siguiente:

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



*Figura 21. Flujo detallado de todo el proceso de experimentación y evaluación.*

#### 4.1. REQUISITOS

Para el desarrollo han sido indispensables los siguientes puntos:

- Conseguir una base de datos de radiografías de tórax lo suficientemente grande, adecuadamente informada y etiquetada para poder entrenar el sistema propuesto.
- Programación con Python para la preparación de la base de datos.
- Utilizar Matlab 2016 para desarrollar el sistema, como lenguaje de programación. No es posible con versiones de MATLAB anteriores.
- Disponer de las librerías Neural Network Toolbox, Parallel Computing Toolbox, Statistics y Machine Learning Toolbox y Computer Vision System Toolbox.
- Una GPU NVIDIA CUDA habilitada con capacidad de cómputo 2.0 o mayor. En nuestro caso agradecemos gratamente el soporte de la Corporación NVIDIA por la donación de una GPU Tesla K40 para este proyecto.
- El último driver compatible con CUDA y la GPU.
- Utilizar la librería de MATLAB MatConvNet, que implementa las redes neuronales convolucionales en MATLAB.

#### 4.2. PREPARACIÓN DE LA BASE DE DATOS

##### 4.2.1. Obtención de los datos

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

Para el proyecto se ha usado una base de datos, a disposición del público, de radiografías de tórax junto con sus informes, que forma parte de Open-I, literatura de código abierto y colecciones de imágenes biomédicas (Open-I). El subconjunto usado de Open-I pertenece a *Indiana Network for Patient Care*, de la Universidad de Indiana y contiene 3955 informes radiológicos y 7470 radiografías de tórax asociadas procedentes de los sistemas de archivos de imágenes de los hospitales (Shin et al, 2016). Todo el conjunto entero ha sido anonimizado mediante una anonimización agresiva, alcanzando el 100% de precisión en el proceso de desidentificación (Demner-Fushman et al, 2015).

[Indiana University Chest X-ray Collection](#)

Kohli MD, Rosenman M - (2013)

Affiliation: Indiana University

ABSTRACT

Comparison: None.

Indication: Pruritic.

Findings: Cardiac and mediastinal contours are within normal limits. The lungs are clear. Bony structures are intact.

Impression: No acute findings.

NOTE: The data are drawn from multiple hospital systems.

[Hide MeSH](#)

Major  
normal

Related in: [MedlinePlus Request Collection](#)



© Copyright Policy - open-access  
License

Related In: Results - Collection  
[Show All Figures](#)

Figure 1: Chest, 2 views, frontal and lateral

**Figura 22.** Ejemplo de una imagen de rayos X de tórax de Open-I junto con su informe





















Como se observa en la Figura 22, en cada informe aparecen cuatro campos: *Comparison*, *Indication*, *Findings* y *Impression*, siguiendo el patrón de un informe radiológico habitual en el diagnóstico de radiografías de tórax.

Para poder conseguir esta base de datos se puso en contacto con el equipo técnico de Open-I, vía petición por la misma página. Se nos proporcionó una base de datos que contenía 10 archivos (.tar.gz) y cada uno tenía el tamaño de alrededor de 7 GB. En total se disponía de 7470 imágenes DICOM.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Índice de ftp://lhcfpt.nlm.nih.gov/outgoing/ceb/NLMCXR\_dcm\_piiRem

 Subir al directorio superior.

Nombre	Tamaño
 1201_1600	
 1601_2000	
 1_400	
 2001_2400	
 2401_2800	
 2801_3200	
 3201_3600	
 3601_4000	
 401_800	
 801_1200	
 NLMCXR_dcm_piiRemoved_1201_1600.tar.gz	6930344 KB
 NLMCXR_dcm_piiRemoved_1601_2000.tar.gz	6917500 KB
 NLMCXR_dcm_piiRemoved_1_400.tar.gz	7314342 KB
 NLMCXR_dcm_piiRemoved_2001_2400.tar.gz	7015428 KB
 NLMCXR_dcm_piiRemoved_2401_2800.tar.gz	6649768 KB
 NLMCXR_dcm_piiRemoved_2800_3200.tar.gz	6741661 KB
 NLMCXR_dcm_piiRemoved_3201_3600.tar.gz	7130548 KB
 NLMCXR_dcm_piiRemoved_3601_4000.tar.gz	6882801 KB
 NLMCXR_dcm_piiRemoved_401_800.tar.gz	6866201 KB
 NLMCXR_dcm_piiRemoved_801_1200.tar.gz	6707894 KB

**Figura 23.** 10 archivos tipo .tar.gz proporcionados por la red de hospitales de la Universidad de Indiana (7470 imágenes tipo DICOM).

#### 4.2.2. Organización y estructuración de los datos

Para poder pasarle las imágenes como datos de entrenamiento a la red neuronal convolucional, se tuvieron que transformar de DICOM a JPEG. La herramienta para llevarlo a cabo fue IrfanView.

IrfanView es un software libre para visualizar/convertir imágenes. Como vemos en la Figura 7, a la derecha se observa la selección de varias imágenes DICOM. La opción Batch conversión y el tipo de imagen al que queremos convertir (JPEG) a la izquierda. Para terminar el proceso se introduce el directorio donde se quiere almacenar la imagen convertida y se pulsa Start Batch.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

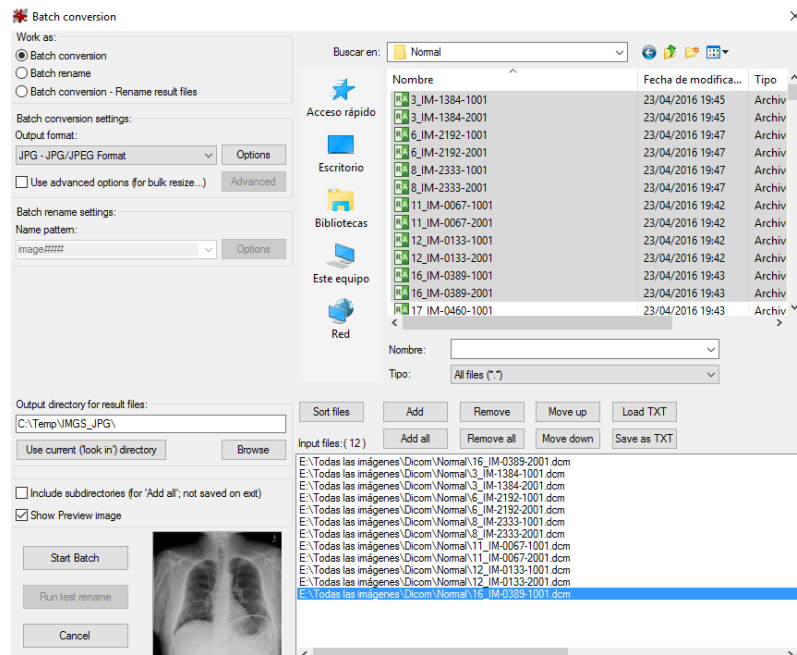


Figura 24. Pasar de DICOM a JPEG con IrfanView.

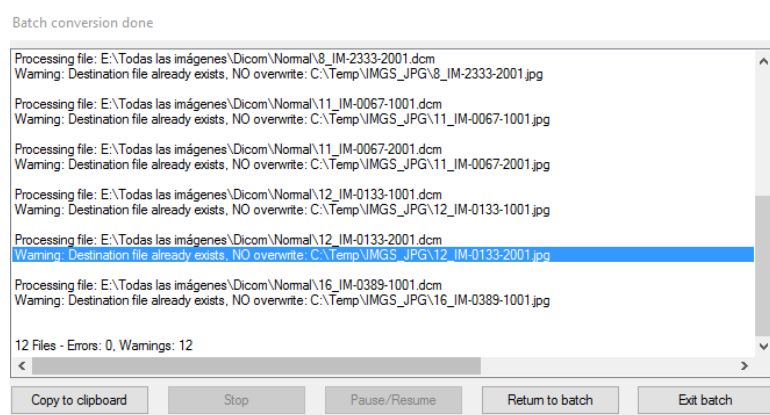


Figura 25. Proceso de conversión de DICOM a JPEG llevado a cabo con éxito de las imágenes seleccionadas previamente en IrfanView.

Además, como se observa en la Figura 5, en cada informe radiológico de Open-I aparecen términos MeSH (Medical Subject Headings, MeSH®), anotados de acuerdo a (Demner et al, 2015). MeSH es el vocabulario tesoro controlado de la *National Library of Medicine*. Consiste en un set de términos nombrando descriptores en una estructura jerárquica que permite buscar en varios niveles de especificidad. Se sabe que esta citación manual de MEDLINE® con términos de vocabulario controlado mejora significativamente la calidad de los resultados de búsqueda de imágenes (Shin et al, 2016).

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Una vez todas las imágenes fueron pasadas a JPEG, se disponía de una carpeta con 7470 imágenes sin ningún informe radiológico ni código MeSH en ninguna de ellas. Para organizarlas en las carpetas deseadas se desarrolló un programa con Python (en Linux) para relacionar el nombre de cada imagen con el código MeSH asociado a esa imagen. Toda esta información se extraía de un código JSON disponible en la plataforma de Open-I (Open-I).

```

{
  "min": 1,
  "max": 100,
  "count": 100,
  "total": 7470,
  "approximage": "false",
  "list": [
    {
      "uid": "CXR1005",
      "pmcid": "1005",
      "note": "The data are drawn from multiple hospital systems.",
      "docSource": "CXR",
      "title": "Indiana University Chest X-ray Collection",
      "fulltext_html_url": "",
      "journal_title": "",
      "journal_abbr": "",
      "journal_date": {
        "day": "01",
        "month": "08",
        "year": "2013"
      },
      "authors": "Kohli MD, Rosenman M",
      "affiliate": "Indiana University",
      "Outcome": [
        {
          "@score": "-0.102",
          "#text": ""
        }
      ],
      "MeSH": {
        "minor": [],
        "major": ["normal"]
      },
      "Problems": "normal",
      "ccLicense": "byncnd",
      "licenseURL": "http://creativecommons.org/licenses/by-nc-nd/4.0/",
      "licenseType": "open-access",
      "abstract": "<p><b>Comparison: </b>None.</p><p><b>Indication: </b>Pruritic. clear. Bony structures are intact.</p><p><b>Impression: </b>No acute findings.</p>",
      "image": {
        "id": "F1",
        "caption": "Chest, 2 views, frontal and lateral",
        "modalityMajor": "x",
        "mention": ""
      },
      "imgThumb": "/imgs/100/203/1005/CXR1005_IM-0006-1001.png",
      "imgLarge": "/imgs/512/203/1005/CXR1005_IM-0006-1001.png",
      "imgThumbLarge": "/imgs/137/203/1005/CXR1005_IM-0006-1001.png",
    }
  ]
}

```

**Figura 26.** Primer fragmento (información de la primera imagen) del código JSON de las 100 primeras imágenes en el que se observa cómo se relaciona la parte principal del MeSH de cada imagen con el nombre de esta, para poderlas clasificar usando un programa propio desarrollado en Python.

Con el programa de Python se fue cogiendo el JSON extraído de la plataforma de Open-I de imágenes en grupos de 100, desde la 1 hasta la 7470. Como la primera agrupación en carpetas que se quería conseguir era en Normales y Anormales, se movió cada una de las 7470 imágenes en que en su MeSH aparecía el término “normal” a una carpeta. Todo el resto se movió a otra carpeta llamada Anormal. En el Apéndice podemos encontrar el código de Python desarrollado.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

En este momento se disponía de 2774 imágenes en la carpeta Normal y 4942 imágenes en la carpeta Anormal. Sin embargo, tanto las normales como en las anormales se combinaban radiografías de tórax de orientación Posteroanterior y Lateral. Para el presente proyecto se decidió centrarse en las de orientación PA, dejando abierta la posibilidad de seguir en trabajos futuros usando también la orientación Lateral, quedando 1387 normales y 2471 anormales.

Mediante modificaciones en el código de Python, de la carpeta de Anormales se eliminaron aquellas que presentaban el campo del MeSH vacío, dejándonos en duda de si se trataba de una imagen sana o patológica. Además, para focalizar el estudio y centrarnos en las patologías cardiopulmonares más comunes, de las imágenes anormales restantes nos quedamos con aquellas en las que en la parte principal (“*major*”) del código MeSH aparecía alguno de los siguientes términos:

- atelectasis → 293 radiografías de tórax Anteroposteriores
- cardiomegaly → 331 radiografías de tórax Anteroposteriores
- nodule → 99 radiografías de tórax Anteroposteriores
- opacity → 412 radiografías de tórax Anteroposteriores
- pleural efusion → 144 radiografías Anteroposteriores

En la agrupación de *nodule* se presentaban pocas imágenes para poder entrenar un clasificador capaz de distinguir entre radiografía de tórax sana y con posible nódulo pulmonar. Es por ello que, tras una extensa búsqueda bibliográfica se encontró una base de datos de la Japanese Society of Radiological Technology (JSRT) de imágenes con (154 radiografías Anteroposteriores) y sin (93 radiografías Anteroposteriores) nódulo pulmonar. Las que presentaban la patología fueron añadidas junto con las 99 anteriores, quedando las agrupaciones de la siguiente manera:

**Tabla 11.** Agrupación final de las imágenes de las clases patológicas según su término MeSH.

Término MeSH	Total
atelectasis	293
cardiomegaly	331
nodule	253
opacity	412
pleural efusion	144

Si se suman las imágenes totales de cada una de las clases patológicas consideradas formarían un total de 1433 imágenes Anormales. Sin embargo, debido a que algunas imágenes presentan varias de estas patologías y se encuentran en varios de los grupos, la categoría Anormal sumaría un total de 868 imágenes radiológicas de tórax.

**Tabla 12.** Agrupación final de las imágenes de rayos X de tórax PA lista para empezar el proceso de extracción de características



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Categoría	Total
Anormal	868
Normal	1387

Ambas carpetas (Anormal y Normal) son incluidas en una carpeta padre que las contiene a la que llamaremos con el nombre de rayos X.

#### 4.3. EXTRACCIÓN DE CARACTERÍSTICAS

Una posibilidad de aprovechar el poder de una Red Neuronal Convolutiva sin exceder el tiempo y la dedicación en formación disponible en este Trabajo de Fin de Grado es utilizar una Red Neuronal Convolutiva preentrenada como extractor automático de características para entrenar un clasificador, mejorando el proceso de entrenar un clasificador extrayendo características de forma manual.

Para construir el algoritmo de reconocimiento en MATLAB, lo que se necesita es, además de la base de datos previamente estructurada y correctamente etiquetada, una CNN preentrenada. Para nuestra experimentación se ha hecho uso del modelo de CNN AlexNet (Krizhevsky et al, 2012) preentrenada en un subconjunto de imágenes de ImageNet (Deng et al, 2009). ImageNet es una exhaustiva base de datos de gran tamaño de imágenes de la vida real no médicas que consiste en 15 Millones de imágenes con más de 20,000 categorías (por ejemplo: instrumentos musicales, herramientas, frutas...).

En 2012, Alex Krizhevsky y otros de la Universidad de Toronto propusieron una arquitectura profunda basada en CNNs que ganó el *Image Large Scale Visual Recognition Challenge*, consiguiendo una mejora sustancial en reconocimiento comparada con otros competidores u otros modelos de años anteriores. Desde entonces se ha convertido en el punto de referencia para la comparación en todas las tareas de reconocimiento. AlexNet es una red neuronal convolutiva preentrenada usando 1.2 millones de imágenes etiquetadas con 1000 clases semánticas. La red empieza con 2 capas convolucionales y pooling mapeando las imágenes de entrada de 227x227 a mapas de características de 13x13. La arquitectura sigue con una secuencia de 3 capas convolucionales que de manera eficiente aplica una capa convolutiva con 9x9 kernels, aun con un mayor grado de no linealidad. La secuencia de capas convolucionales es seguida con una capa pooling y 3 capas totalmente conectadas. La primera capa totalmente conectada se puede ver como una capa convolutiva con 6x6 kernels y las otras dos capas totalmente conectadas como capas convolucionales de 1x1 kernels (Krizhevsky et al, 2012). Para poder obtener AlexNet se puede acudir a (AlexNet).

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

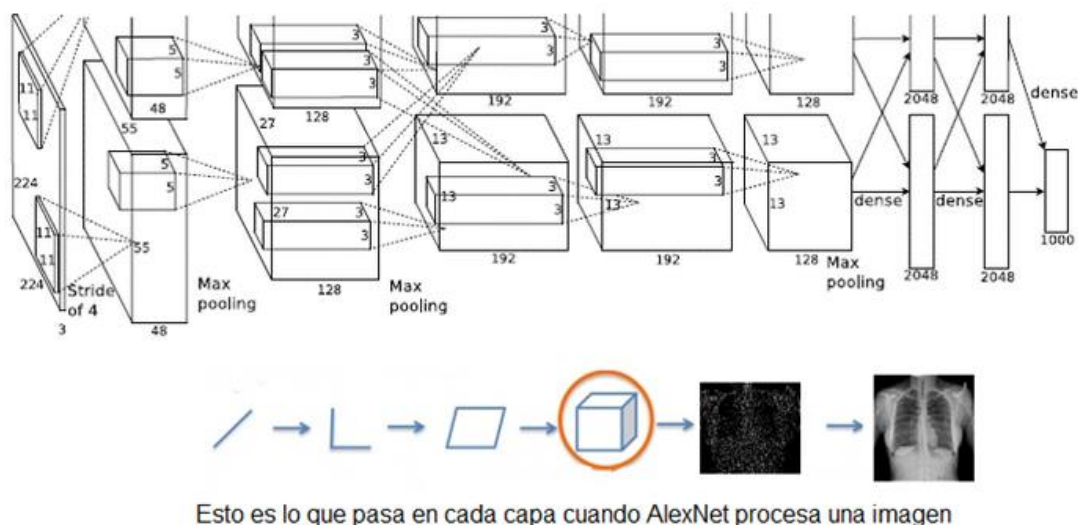


Figura 27. Esquema de AlexNet, una red neuronal convolucional entrenada a partir de ImageNet.

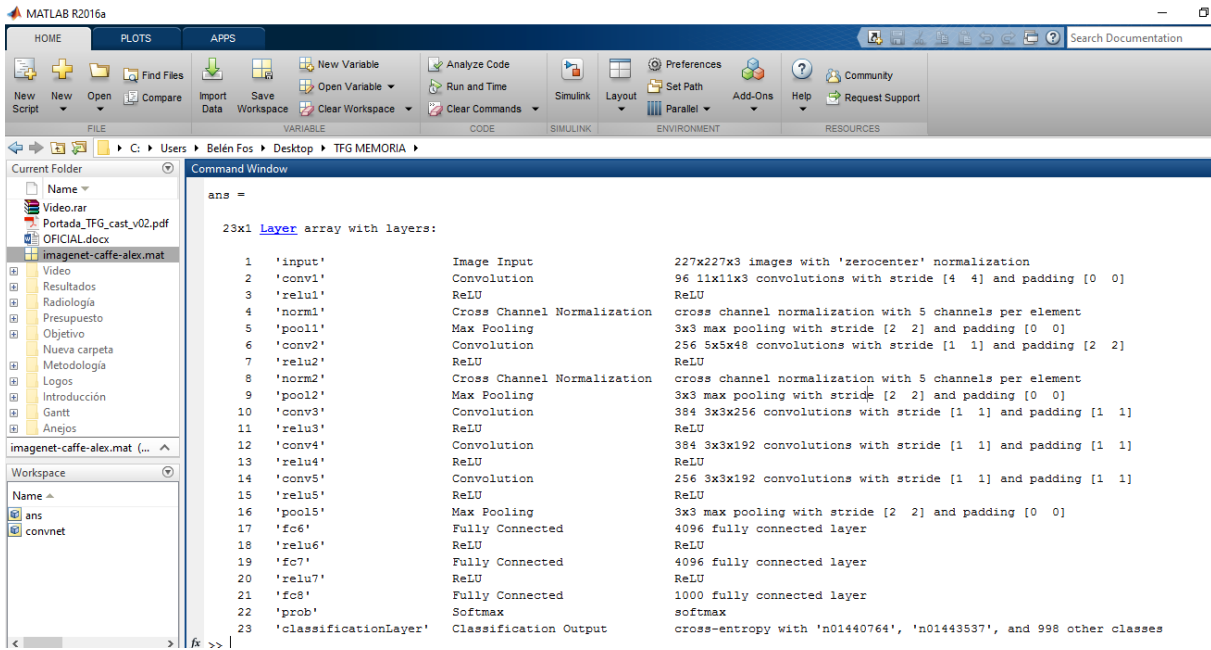
Tabla 13. Estructura y parámetros de AlexNet, una CNN preentrenada.

CAPA	TIPO	ENTRADA	KERNEL	PASO	RELLENO	SALIDA
datos	entrada	3x227x227	N/A	N/A	N/A	3x227x227
conv1	convolución	3x227x227	11x11	4	0	96x55x55
pool1	max pooling	96x55x55	3x3	2	0	96x27x27
conv2	convolución	96x27x27	5x5	1	2	256x27x27
pool2	max pooling	256x27x27	3x3	2	0	256x13x13
conv3	convolución	256x13x13	3x3	1	1	384x13x13
conv4	convolución	384x13x13	3x3	1	1	384x13x13
conv5	convolución	384x13x13	3x3	1	1	256x13x13
pool5	max pooling	256x13x13	3x3	2	0	256x6x6
fc6	fully connected	256x6x6	6x6	1	0	4096x1
fc7	fully connected	4096x1	1x1	1	0	4096x1
fc8	fully connected	4096x1	1x1	1	0	1000x1

Seguidamente procedemos a importar la CNN en el entorno de MATLAB. Para poder importarla como **SeriesNetwork** (objeto de MATLAB que contiene las capas de la red entrenada dispuestas una tras otra donde solo hay una entrada y una salida) hacemos uso de **helperImportMatConvNet** (importa

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

una red MatConvNet en un objeto SeriesNetwork de la herramienta Neural Network proporcionándose solo con fines educativos).



**Figura 28.** En el entorno de MATLAB se observa que la arquitectura de la CNN importada coincide con el esquema y los parámetros de AlexNet expuestos anteriormente (**convnet.Layers**)

Como se ha comentado con anterioridad se han almacenado las imágenes en carpetas de rayos X de pulmón Normal y Anormal separadas bajo una carpeta que las contiene llamada rayos X. La ventaja de utilizar esta estructura de carpetas es que el **imageDatastore** de MATLAB que creamos será capaz de leer y administrar las ubicaciones de imágenes y etiquetas con una categoría de forma automática. (ImageDatastore es un repositorio para colecciones de datos que son demasiado grandes para caber en la memoria). Inicializamos un imageDatastore para acceder a las imágenes en MATLAB de la carpeta de rayos X, creando un objeto para colecciones de datos de imágenes.

Para tener el mismo número de imágenes de una clase que de otra y que así las características tengan el mismo peso se usan los siguientes comandos:

- **countEachLabel** → cuenta el número de archivos que hay en cada una de las categorías del imageDatastore.
- **min** → se queda con el menor número de imágenes de cada una de las carpetas.
- **splitEachLabel** → divide el imageDatastore en proporciones, que en este caso será el mínimo obtenido anteriormente.

Debido a que la red AlexNet se entrenó en imágenes de 227x227 píxeles, tenemos que redimensionar todas nuestras imágenes de entrenamiento a la misma resolución. Después de


*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

redimensionar las imágenes, estas quedan de 227x227x3 píxeles. La tercera dimensión describe los tres canales de color. Las imágenes proporcionadas eran en escala de grises así que se replicó uno de los canales en los otros dos restantes. En el Anexo podemos encontrar la función empleada para llevarlo a cabo.

Queremos usar este nuevo conjunto de datos para preentrenar la CNN AlexNet. Como se ha detallado anteriormente, primero se entrena una red neuronal convolucional a partir de imágenes naturales no médicas y seguidamente y tras haber aprendido a sacar diferencias de clases, se aplica esta CNN preentrenada para extraer características de una base de datos de imágenes médicas y entrenar un clasificador. En nuestro caso la clasificación es entre imágenes de rayos x normales y anormales.

Se pasan los datos de entrenamiento a través de la CNN y se usa el método de activaciones para extraer características en una capa particular de la red. Como se ha comentado anteriormente, las CNNs se forman usando capas interconectadas de elementos de procesamiento no lineales o neuronas. Las capas de entrada y de salida conectan con las señales de entrada y de salida, y las capas ocultas proporcionan complejidad no lineal que le da a una red neuronal su capacidad computacional.

Las capas del principio de la red capturan características básicas de la imagen, tales como ejes y manchas.



**Figura 29.** Características de bajo nivel tras las activaciones de la primera capa de la CNN (manchas, ejes...).

Las primeras capas de la red han aprendido filtros para capturar características como manchas y ejes. Estas características primitivas son procesadas por capas más profundas de la red, que combinan las características tempranas para formar características de la imagen de más alto nivel (contornos, categorías...). Estas características de más alto nivel son más adecuadas para tareas de reconocimiento porque combinan todas las características primitivas en una imagen de representación más rica (Deng et al, 2013).

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

El método de **activations** Calcula las activaciones de la capa de la red para una capa específica. Las activaciones de la red se calculan propagando hacia delante la entrada X a través de la red hasta llegar a la capa específica. La capa debe tener un índice numérico o un vector de caracteres correspondiente a uno de los nombres de la red. Para una red que la capa de entrada es una imagen, X tiene que ser:

- Una imagen
- Una matriz de 4D donde las tres primeras dimensiones son el alto, el ancho y los canales de la imagen y la cuarta dimensión indica las imágenes individuales.
- Un conjunto de datos de imágenes

La Y que es la salida será una matriz con una fila por observación. Cada fila de la matriz es una observación y cada columna es un elemento de salida de la capa elegida. Por defecto y si no se dice lo contrario nos lo dará de esta manera aunque habría otras opciones.

El MiniBatchSize es el tamaño de los mini-lotes para las predicciones de computación. Los tamaños mayores de mini-lotes conducen a predicciones más rápidas, a costa de más memoria. Por defecto sería 128.

```
Y = activations(net, X, layer)
```

En nuestro caso se han obtenido las características de la fc6 (capa totalmente conectada 6), basándonos en los resultados experimentales llevados a cabo en (Bar et al, 2013; Bar et al, 2015).

```
trainingFeatures = activations(convnet, trainingSet, featureLayer,  
                              'MiniBatchSize', 32, 'OutputAs', 'columns');
```

Para cada imagen de entrada se obtiene un vector de características usando AlexNet. La información de la imagen se mueve desde la capa de entrada hasta la capa de salida a través de capas internas. Cada capa es una combinación de pesos de las capas anteriores, es decir, una representación de características de la imagen de entrada. Para capturar abstracciones de alto nivel tenemos que transferir el conocimiento de características obtenidas de las últimas capas (totalmente conectadas). No debemos extraer características de la última capa porque esta solo proporciona la probabilidad de la clase predicha (no es una representación de la imagen de entrada).

Como se ha comentado anteriormente nos hemos quedado con el mismo número de imágenes de una categoría que de otra, restringiéndonos al menor de los totales de imágenes de ambas clases (868 imágenes Anormales y 868 Normales). Se han extraído características de todas ellas con AlexNet, mediante el método **activations** de la capa fc6. El resultado obtenido es una matriz de 1376x4096 siendo 1376 el total de observaciones y 4096 las características obtenidas de cada una de las observaciones.

Para poder entrenar el clasificador se ha construido una tabla de 1376x4097, siendo las 1376 filas las observaciones de imágenes Anormales y Normales, las 4096 primeras columnas las características

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

extraídas de cada una de ellas mediante las activaciones de la fc6 y la última columna, las etiquetas de cada una de las observaciones. Esta es la estructura necesaria que se debe introducir en la App Classification Learner de MATLAB.



**Figura 30.** Descripción final de los datos introducidos para entrenamiento y test del clasificador.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

	4088 trainingFeatures4088	4089 trainingFeatures4089	4090 trainingFeatures4090	4091 trainingFeatures4091	4092 trainingFeatures4092	4093 trainingFeatures4093	4094 trainingFeatures4094	4095 trainingFeatures4095	4096 trainingFeatures4096	4097 Group
1	-24.4161	-27.5500	12.6157	-7.0282	17.5536	-2.5497	-4.4617	-1.5894	22.6259	Anormal
2	-22.8070	-26.7173	2.0166	-11.3433	20.7727	4.3099	1.0748	-2.7540	13.5863	Anormal
3	-12.3604	-36.5539	7.4275	-21.7599	20.1256	7.9280	0.0261	-7.2720	2.4100	Anormal
4	-15.4050	-18.3228	5.6993	-11.8387	6.7896	-4.5410	-0.3537	-5.9379	22.6057	Anormal
5	-22.2318	-33.0294	5.9654	-13.8717	14.6584	-5.5572	-1.5397	0.0071	5.0293	Anormal
6	-30.8844	-24.5241	-11.1324	-22.4150	26.6407	7.3083	-10.5174	-9.2347	17.4724	Anormal
7	-26.1835	-30.3041	4.8635	-17.7564	16.0278	3.2328	-2.4700	-4.4224	22.5399	Anormal
8	-26.1835	-30.3041	4.8635	-17.7564	16.0278	3.2328	-2.4700	-4.4224	22.5399	Anormal
9	-47.6632	-18.0238	-6.9545	-25.9825	34.6858	-5.0019	-3.9928	-7.2392	9.3866	Anormal
10	-26.3487	-34.8682	-14.0244	-22.8860	18.2761	11.7339	-4.4030	-15.2275	20.2976	Anormal
11	-10.0458	-31.9494	13.7471	-17.6218	11.8409	13.9132	4.0489	-10.3882	13.6271	Anormal
12	-32.4317	-29.3433	2.3198	-10.0987	13.6386	-3.8829	-10.3877	-14.7518	28.1325	Anormal
13	-22.6101	-29.2817	11.5493	-18.3258	9.0628	5.5256	-3.9922	-9.0579	22.2474	Anormal
14	-28.0596	-31.6609	2.8009	-20.9417	18.3767	-0.3235	-12.8018	-11.5722	18.1964	Anormal
15	-14.9840	-39.6525	-3.4217	-26.4394	10.9281	2.4388	-6.2129	-19.6208	4.9731	Anormal
16	-24.9987	-33.1664	-15.1057	-12.7215	-1.7088	25.1724	-19.7255	-23.1420	13.0853	Anormal
17	-28.3732	-24.8039	-16.7571	-21.6896	18.3315	6.0364	-9.7916	-14.7860	20.6635	Anormal
18	-20.5316	-32.9083	3.9667	-21.1827	19.2315	1.0337	-2.6549	0.0333	10.7705	Anormal
19	-25.3932	-28.4780	18.4893	-12.5664	18.8239	-8.8122	-4.0953	-1.5276	16.2222	Anormal
20	-15.0625	-16.4899	6.2186	-11.0543	21.4243	12.7492	-11.4230	-5.6714	21.5813	Anormal
21	-28.1649	-31.5961	6.9259	-6.3760	22.2013	-1.9962	-4.1568	4.8233	16.9448	Anormal
22	-16.3144	-30.6458	-5.7396	-8.7020	24.6199	10.4128	-7.5505	-13.1551	25.4196	Anormal
23	-25.0499	-23.0347	-1.5494	-15.9981	11.5292	21.1201	-2.7714	-9.5254	11.4614	Anormal
24	-21.7392	-23.6656	12.2507	-18.7246	9.6969	-4.5772	-3.6919	-0.5116	16.5664	Anormal

Figura 31. Tabla que contiene 1736 observaciones (868 Anormales y 868 Normales) en las filas y 4096 características obtenidas de forma automática por AlexNet de cada una de ellas, junto con las etiquetas de cada clase. Esta es la estructura necesaria que se debe introducir para entrenar un clasificador con la Classification Learner App de MATLAB.

#### 4.4. ENTRENAMIENTO DE UN CLASIFICADOR

Ahora ya se puede proceder a entrenar un clasificador "superficial" con las características extraídas en el paso anterior. La red original fue entrenada para clasificar 1000 categorías de objetos. El clasificador "superficial" será capaz de resolver un problema binario entre radiografías de tórax normales o patológicas.

La aplicación Classification Learner de MATLAB, de la Machine Learning Toolbox entrena modelos para clasificar datos. Usando esta aplicación se puede explorar el *machine learning* supervisado usando varios clasificadores. Se pueden explorar los datos, seleccionar características, especificar esquemas de validación cruzada, entrenar modelos y evaluar resultados. Puedes llevar a cabo entrenamiento automático para buscar el mejor tipo de modelo clasificador (árboles de decisión, análisis discriminante, máquinas de vector soporte, regresión logística, vecinos próximos, clasificación ensamblada).

Como se observa en la Figura 32, se selecciona la tabla previamente descrita cuya estructura es necesaria para esta aplicación. El clasificador va a ser entrenado con el 80% de los datos y el 20% restante se va a usar para validar y evaluar el sistema.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

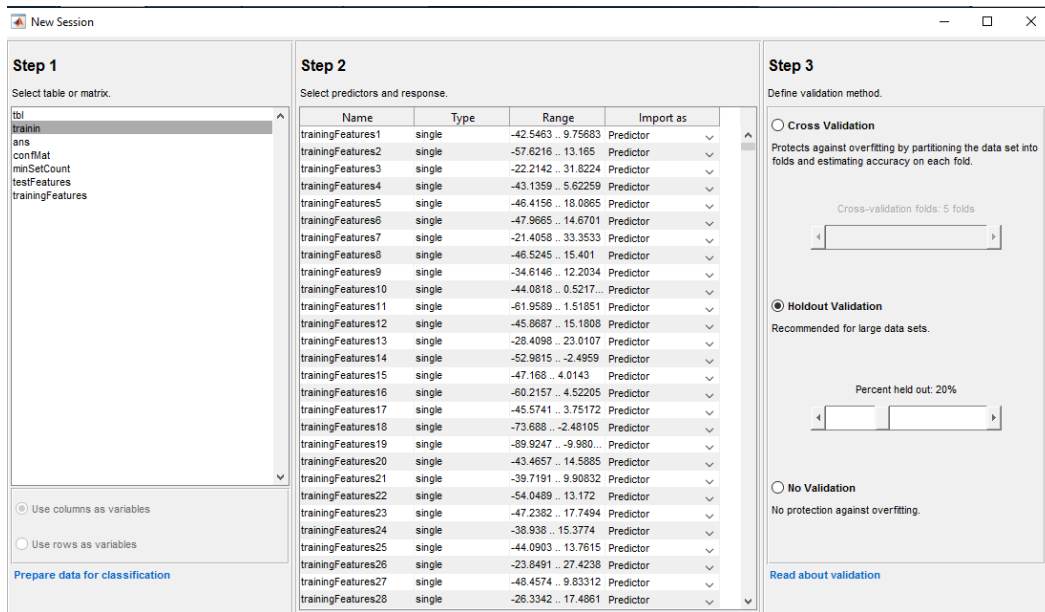


Figura 32. Preparación de los datos en la App Classification Learner de MATLAB.




Figura 33. Comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App. Se puede observar que el mejor modelo clasificador se consigue con un SVM de kernel lineal.



“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 34. Segunda parte de la Comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App.

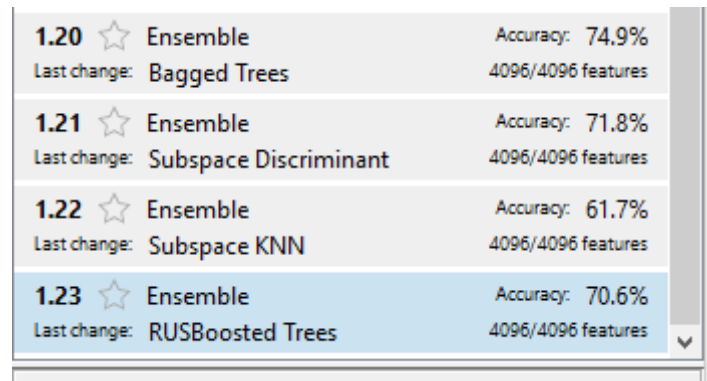


Figura 35. Tercera parte de la comparación de la ACC obtenida por los distintos modelos clasificadores entrenados con Classification Learner App.

#### 4.5. OTRAS TAREAS DE CLASIFICACIÓN

Además de la tarea principal, se han incluido otras tareas de screening en la clasificación de radiografías de tórax. Entre ellas tenemos la separación entre

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

a) Atelectasia frente a Normal (no presenta atelectasia)

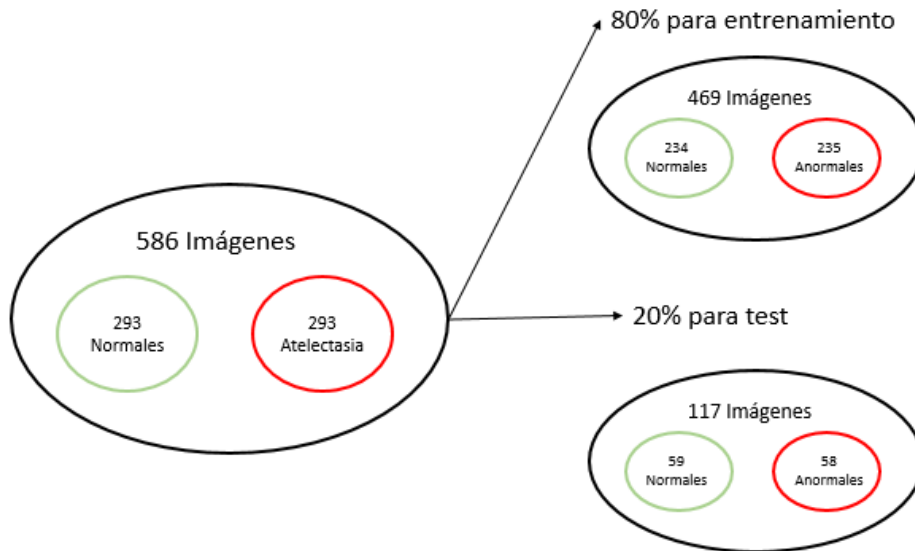


Figura 36. Descripción de los datos para entrenamiento y test del clasificador: Atelectasia vs. Normal

b) Cardiomegalia frente a Normal (no presenta cardiomegalia)

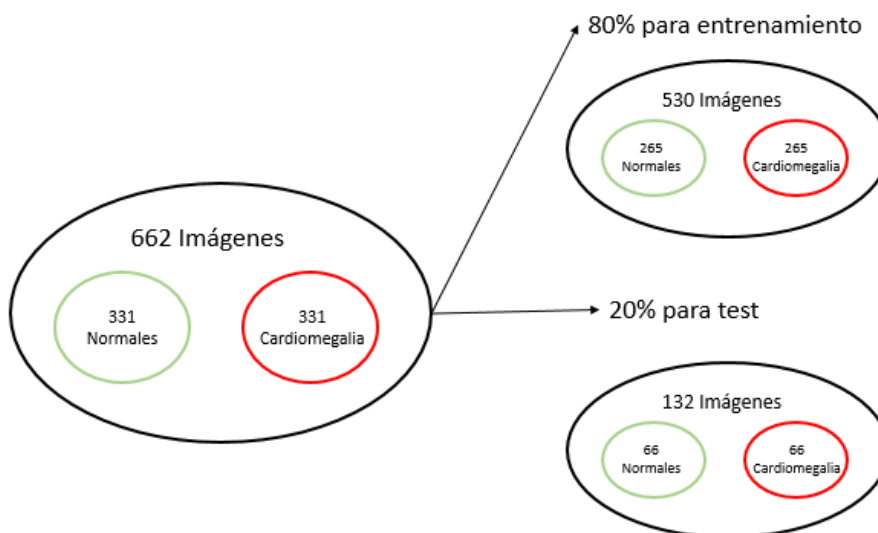


Figura 37. Descripción de los datos para entrenamiento y test del clasificador: Cardiomegalia vs. Normal

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

c) Efusión pleural frente a Normal (no presenta efusión pleural)

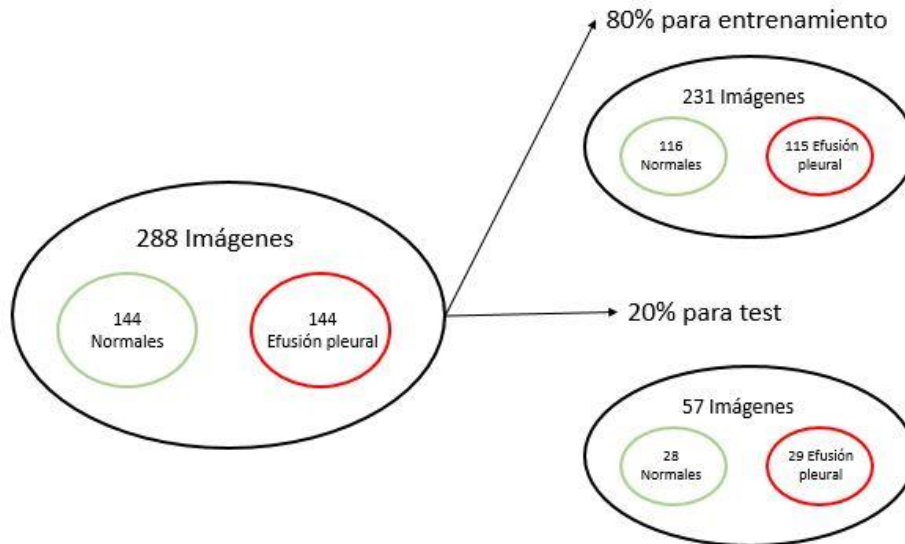


Figura 38. Descripción de los datos para entrenamiento y test del clasificador: Efusión pleural vs. Normal

d) Nódulo frente a Normal (no presenta nódulo)

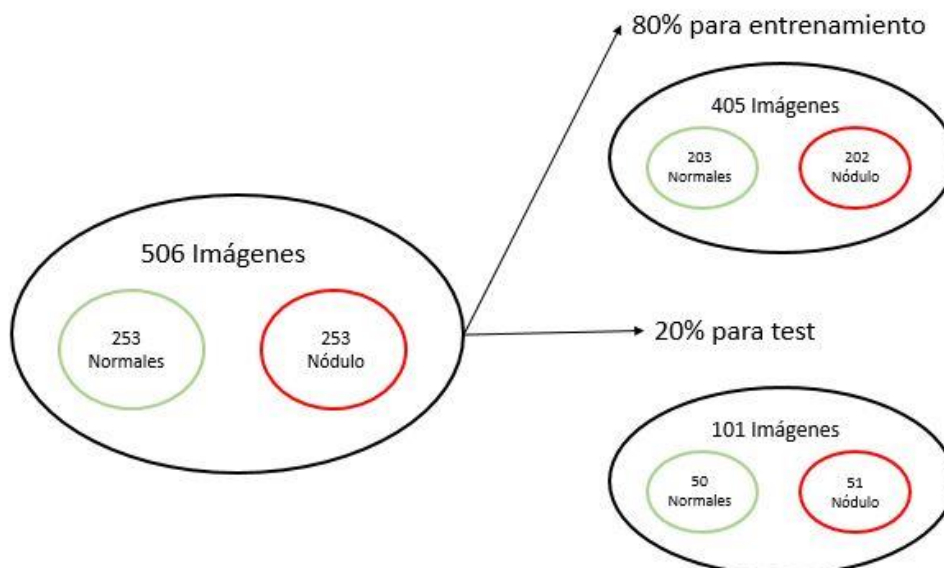
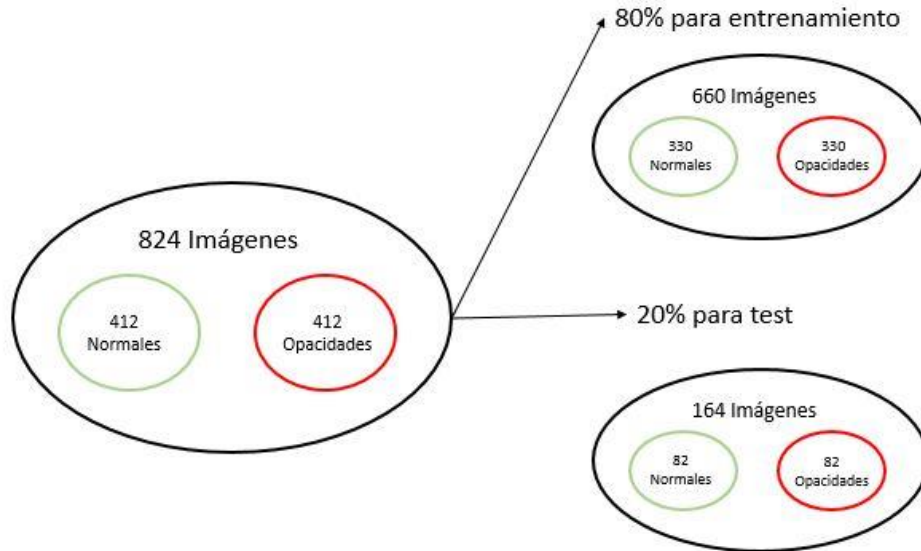


Figura 39. Descripción de los datos para entrenamiento y test del clasificador: Nódulo vs. Normal

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

e) Opacidad frente a Normal (no presenta opacidad)



**Figura 40.** Descripción de los datos para entrenamiento y test del clasificador: Efusión pleural vs. Normal

En todas estas tareas de clasificación de radiografías Anteroposteriores de tórax se va a proceder de la misma forma que la comentada para el caso general: extrayendo características de forma automática con AlexNet de todas las imágenes de ambas categorías y usando las mismas para entrenar un clasificador SVM lineal.

#### 4.6. USO DE GPU

Para todos los procesos que involucran la extracción de características usando AlexNet, se requieren GPUs. En este caso se ha hecho uso de una Tesla K40 proporcionada por NVIDIA, para reducir el tiempo de entrenamiento y de predicción, reduciendo entre 10 y 15 veces el tiempo que tarda en hacer el mismo procedimiento la CPU, pues los algoritmos de CNNs son intensos computacionalmente y pueden ser lentos de ejecutar.

Para ello se hace uso de la función **gpuArray** (de la Parallel Computing Toolbox de MATLAB), incluida en la función **activations**, previamente mencionada.

#### 4.7. IMPLEMENTACIÓN DEL SISTEMA

Una vez se entrenados todos los clasificadores y exportados en un archivo .mat al que hemos llamado FIN.mat se ha desarrollado una interfaz gráfica de usuario personalizada sencilla para facilitar la interacción (simplemente con el ratón) del profesional con el software de clasificación. Para llevarlo

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

a cabo hemos diseñado una GUI con GUIDE de MATLAB, simplemente introduciendo **guide** en el entorno principal.

GUIDE es un entorno de programación visual disponible en MATLAB para realizar y ejecutar programas que necesiten ingreso continuo de datos. Tiene las características básicas de todos los programas visuales como Visual Basic o Visual C++ (Barragán, 2007).

Para empezar se diseñar la parte gráfica de la interfaz. Se tiene que definir el uso que se le quiere dar para que contenga todos los elementos relevantes en la interacción entre la máquina y el clínico. Se pueden añadir botones push, de radio o de activación o grupos de botones, texto estático o editable, deslizadores de opciones, casillas de verificación, menús emergentes, cuadros de listas, tablas, paneles, ejes, gráficas, dependiendo de la finalidad del sistema.

En nuestro caso se desea cargar una imagen (de rayos X de tórax PA) de cualquier ordenador, mostrándose por pantalla. Esta imagen se va a pasar como nueva tarea de clasificación a los clasificadores previamente entrenados y almacenados en FIN.mat. Finalmente, el sistema debe proporcionar la clasificación de la imagen de la forma más similar a un informe radiológico real.

Es por ello que se ha usado un texto estático para el título del sistema y otros tres para las clases tipo de imagen región y orientación de la misma, push button para cargar la imagen, un axes donde se puede visualizar tras ser cargada. Dos push button más son añadidos: uno para empezar la lectura radiológica de la imagen y otro para resetear el sistema, dejándolo en su estado inicial (sin imagen en el axes y sin ninguna información diagnóstica). Los push buttons van asociados a una función que se lleva a cabo tras ser presionados. Toda la información radiológica va a estar contenida en cuadros de texto dentro de un panel, que mostrarán la etiqueta obtenida tras pasar la imagen por los distintos clasificadores, determinando de si se trata de una radiografía de tórax normal o anormal y que patologías presenta.

Una vez finalizado el diseño gráfico de la GUI, se exporta en forma de archivo .m (código que se puede modificar para conseguir las funciones deseadas) y .fig (archivo que contiene la información visual).

## CAPÍTULO 5. RESULTADOS

La evaluación del sistema de clasificación es una parte integral del proceso de desarrollo de un clasificador. Se trata de un aspecto importante para medir el rendimiento del sistema, es decir, una estimación objetiva de cómo el clasificador actuaría con datos nuevos en un futuro.

El rendimiento clínico de experimentos médicos, incluyendo la imagen médica está normalmente determinado por estimar los índices de verdaderos positivos (TPR), verdaderos negativos (TNR), falsos positivos (FPR), falsos negativos (FNR), sensibilidad, especificidad y precisión, entre otros (Fernández y Díaz, 2003). Las matrices de confusión también se usan de manera habitual.

### 5.1. ÍNDICES DEL RENDIMIENTO CLÍNICO

Una **matriz de confusión** es una tabla que se usa normalmente para describir el rendimiento de un sistema de clasificación en un conjunto de datos en el que se conocen los verdaderos valores. La matriz contiene información de las clasificaciones reales y las predichas realizadas por el sistema y se usa para calcular el desempeño del algoritmo (Visa et al., 2011).

La matriz de confusión para un clasificador binario presentaría la siguiente forma:

*Tabla 14. Matriz de confusión general.*

		Clase predicha	
		Condición Positiva Predicha	Condición Negativa Predicha
Clase real	Condición Positiva	Verdaderos Positivos	Falsos Negativos
	Condición Negativa	Falsos Positivos	Verdaderos Negativos

Como se observa en la Tabla , una matriz de confusión presenta dos filas y dos columnas. En cada una de las celdas encontramos información de los Verdaderos Positivos, Falsos Positivos, Falsos Negativos y Verdaderos Negativos. Esto nos permite obtener más información que simplemente el *Accuracy* del sistema, que no es una métrica del todo fiable del rendimiento del clasificador (llegando a dar resultados erróneos si el conjunto de datos está desequilibrado, es decir, que el número de muestras de una clase difiere mucho de las de la otra).

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

---

A partir de ella se pueden obtener varios términos estándar que se han definido para un clasificador binario:

- La **Accuracy** es la proporción del número total de predicciones que son correctas. Se calcula de la siguiente forma:

$$Accuracy (ACC) = \frac{\sum Verdaderos Positivos + \sum Verdaderos Negativos}{\sum Población total} = \frac{TP+TN}{P+N} \quad (6)$$

- El **Valor Predictivo Positivo (PPV) o Precisión** es la proporción de los casos positivos predichos que son correctos:

$$PPV \text{ ó } Precisión = \frac{\sum Verdaderos Positivos}{\sum Salidas de test positivas} = \frac{TP}{TP+FP} \quad (7)$$

- El **Ratio de Verdaderos Positivos (TPR) o Sensibilidad** es la proporción de casos positivos que se han identificado correctamente:

$$TPR \text{ ó } Sensibilidad = \frac{\sum Verdaderos Positivos}{\sum Condición Positiva} = \frac{TP}{TP+FN} \quad (8)$$

- El **Ratio de Verdaderos Negativos (TNR) o Especificidad** se define como la proporción de casos negativos que se han clasificado correctamente:

$$TNR \text{ ó } SPC = \frac{\sum Verdaderos Negativos}{\sum Condición Negativa} = \frac{TN}{TN+FP} \quad (9)$$

- El **Ratio de Falsos Positivos (FPR)** es la proporción de casos negativos que fueron clasificados incorrectamente como positivos. Este corresponde con el error Tipo I.

$$FPR = \frac{\sum Falsos Positivos}{\sum Condición Negativa} = \frac{FP}{FP+TN} = 1 - SPC \quad (10)$$

- El **Ratio de Falsos Negativos (FNR)** es la proporción de casos positivos clasificados incorrectamente como negativos, correspondiendo con el error Tipo II.

$$FNR = \frac{\sum Falsos Positivos}{\sum Condición Negativa} = \frac{FN}{FN+TP} = 1 - TPR \quad (11)$$

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

---

- La **Prevalencia** es la frecuencia con la que la condición positiva se produce en nuestra muestra:

$$\text{Prevalencia} = \frac{\sum \text{Condición Positiva}}{\sum \text{Población total}} = \frac{FP}{FP+TN} = 1 - SPC \quad (12)$$

Además de las matrices de confusión, otra forma de examinar los rendimientos de los clasificadores son los **gráficos ROC** (Receiver Operating Characteristics) son una técnica de visualización, organización y selección de clasificadores basada en su rendimiento (Fawcett et al, 2006). Suelen ser habituales en la toma de decisiones médicas y, recientemente, se está aumentando su uso de forma considerable en el aprendizaje automático (*machine learning*) y en investigación en minería de datos. El gráfico presenta el Ratio de Falsos Positivos en el eje X y el Ratio de Verdaderos Positivos en el eje Y.

- El punto (0,1) es el clasificador perfecto (clasifica todos los casos positivos y negativos correctamente). Se trata de (0,1) porque el Ratio de Falsos Positivos es 0 y el Ratio de Verdaderos Positivos es 1.
- El punto (0,0) representa un clasificador que predice todos los casos como negativos.
- El punto (1,1) corresponde con un clasificador que predice todos los casos como positivos.
- El punto (1,0) es el clasificador que es incorrecto en todas sus clasificaciones.

En muchos casos, un clasificador tiene un parámetro que se puede ajustar para aumentar el TPR a costa de un aumento del FPR o disminuir el FPR a costa de una disminución del TPR. Cada ajuste de parámetros proporciona un par (FPR, TPR) y una serie de estos pares se puede usar para representar una curva ROC.

La curva ROC encapsula toda la información contenida en la matriz de confusión, desde que el FNR es complementario del TPR y el TNR es el complemento de FPR. Esta proporciona una herramienta visual para examinar la solución de compromiso entre la habilidad de un clasificador de identificar correctamente casos positivos y el número de casos negativos que están incorrectamente clasificados.



“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 41. Ejemplo de curva ROC.

Se sugiere que el área debajo de la curva ROC (AUC) se use como medida de precisión en muchas aplicaciones. AUC se usa habitualmente como medida de la calidad de modelos de clasificación. Un clasificador aleatorio presenta un área bajo la curva de 0.5 mientras que el perfecto clasificador presentaría un valor igual a 1. En la práctica, la mayoría de modelos de clasificación presentan una AUC de entre 0.5 y 1.




Figura 42. Ejemplo de AUC de la curva ROC de la Figura.

## 5.2. RESULTADOS EXPERIMENTALES

La tarea principal del proyecto era entrenar un clasificador capaz de separar entre imágenes radiológicas de tórax normales y patológicas. Tras extraer características de imágenes Normales y Anormales, se procedió a entrenar varios clasificadores mediante la Classification Learner App de MATLAB. En este apartado se va a poder comparar el rendimiento de los mismos (la ACC y el tiempo

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

empleado para el entrenamiento), seleccionando el que obtiene una mayor precisión y se adecue mejor a nuestro sistema.

Una vez decidido el clasificador adecuado para nuestra clasificación en concreto, este va a ser entrenado para distintas tareas de clasificación de radiografías de tórax, evaluándolo mediante la matriz de confusión, los índices de evaluación clínica que se extraen de ella, la curva ROC y el AUC.

Además, se va a mostrar la interfaz gráfica de usuario (GUI) desarrollada para facilitar la interacción del sistema con el médico especialista, partiendo de la primera versión y finalizando con una mucho más completa y compleja.

### 5.2.1. Comparativa entre los distintos clasificadores entrenados

Como se observa en la Tabla 15, la mayor precisión se ha alcanzado usando un modelo de clasificación SVM con kernel lineal, consiguiendo un valor del 83%. El tiempo empleado por el mismo es relativamente bajo en comparación con Ensemble (Boosted Trees), que es el modelo que más ha tardado. KNN (coarse KNN) ha sido el clasificador entrenado más rápidamente.

**Tabla 15.** Rendimiento de distintos clasificadores entrenados para una tarea de clasificación entre Normal y Anormal.

CLASIFICADOR	ACC	Tiempo (segundos)
Árbol (complejo)	67.7%	49.867
Árbol (medio)	70.0%	40.16
Árbol (simple)	72.3%	25.116
Discriminación lineal	63.4%	13.503
Discriminación cuadrática	65.1%	7.6696
Regresión logística	52.7%	63.38
<b>SVM Lineal</b>	<b>83.0%</b>	14.127
SVM cuadrático	82.1%	14.427
SVM cúbico	80.1%	15.354
SVM (fine gaussian)	54.5%	18.427
SVM (medium gaussian)	80.7%	14.289
SVM (coarse gaussian)	78.4%	14.732
KNN (fine KNN)	63.4%	9.1041
KNN (medium KNN)	72.9%	6.9112
KNN (coarse KNN)	66.3%	6.8689
KNN (cosine KNN)	72.0%	7.1948
KNN (cubic KNN)	73.8%	124.1
KNN (weighted KNN)	72.3%	6.8908
Ensemble (Boosted Trees)	79.0%	510.16
Ensemble (Bagged Trees)	74.9%	17.921
Ensemble (Subspace Discriminant)	71.8%	257.27

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Ensemble (Subspace KNN)	61.7%	56.919
Ensemble (RUSBoosted Trees)	70.6%	474.46

Como el clasificador que **mejor** se adapta a nuestro sistema es el **SVM** (Hearst et al, 2002) **lineal**, se ha usado este modelo para todas las tareas de clasificación de radiografías de tórax, evaluando a continuación el rendimiento del mismo.

### 5.2.2. Evaluación del SVM en distintas tareas de clasificación

Una vez se lleva a cabo la validación de cada uno de los clasificadores con los datos de prueba se genera una matriz de confusión. A continuación se van a exponer las distintas matrices obtenidas a modo de muestra de los experimentos llevados a cabo. A partir de ellas se pueden obtener los distintos índices de rendimiento clínico.

El proceso de evaluación del modelo con los datos de entrenamiento no es aceptable porque puede generar fácilmente modelos demasiado optimistas y sobre ajustados. Hay dos métodos de evaluación de modelos. Uno de ellos es Hold-Out y el otro es la Validación cruzada. Para evitar el sobreajuste, ambos métodos usan un conjunto de test (que no ha sido visto por el modelo) para evaluar el rendimiento del mismo.

En este caso se ha escogido el método de Hold-Out puesto que es aconsejable en conjuntos más o menos grandes de datos. El conjunto de datos ha sido dividido de forma aleatoria en datos de entrenamiento y de test, dejando un **80%** para entrenamiento y el **20%** restante para probar el sistema. **La distribución de los datos ha sido detallada en el apartado de Material y Métodos.**

- Conjunto de entrenamiento → subconjunto de los datos usado para entrenar al clasificador.
- Conjunto de test → subconjunto de los datos usado para estimar la tasa de error del clasificador entrenado o evaluar el rendimiento futuro.

Detallando los posibles errores, FPR indica una mala clasificación indeseable, puesto que tiene un impacto en los costes y entrega de servicio sanitario. Se trata de los casos en los que se determinan como patológicos los casos sanos, conduciendo a hacer más pruebas diagnósticas o a llevar a cabo algún tratamiento.

Pero el error que más nos preocupa es el FNR porque lleva a un inadecuado seguimiento de los pacientes y provoca que se pasen por alto casos de enfermedad.

Por otro lado, SENS o sensibilidad es la probabilidad de una respuesta positiva para los casos patológicos. SPEC o especificidad es la probabilidad de una respuesta negativa para los casos con ausencia de patología.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

a) Anormal frente a Normal




Figura 43. Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Anormal y Normal.




Figura 44. Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 43.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 45. Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Atelectasia y Normal.

**b) Atelectasia frente a Normal (no atelectasia)**

La categoría Normal en este caso se refiere a ausencia de Atelectasia.



Figura 46. Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Atelectasia y Normal.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

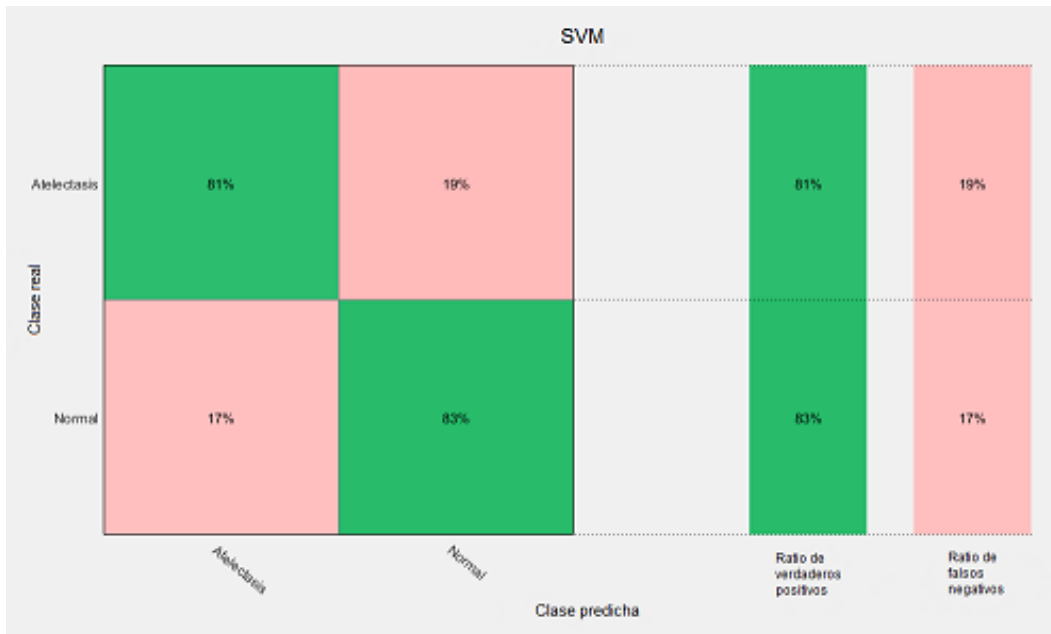


Figura 47. Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 46.





Figura 48. Curva ROC Y AUC en la clasificación entre categoría Atelectasia y Normal.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**c) Cardiomegalia frente a Normal (no cardiomegalia)**

La categoría Normal en este caso se refiere a ausencia de Cardiomegalia.



**Figura 49.** Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Cardiomegalia y Normal.



**Figura 50.** Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 49.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 51. Curva ROC Y AUC en la clasificación entre categoría Cardiomegalia y Normal.

**d) Efusión pleural frente a Normal (no efusión pleural)**

La categoría Normal en este caso se refiere a ausencia de Efusión pleural.




Figura 52. Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Efusión pleural y Normal.



“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 53. Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 52.





Figura 54. Curva ROC Y AUC en la clasificación entre categoría Efusión pleural y Normal.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**e) Nódulo frente a Normal (no presenta nódulo)**

La categoría Normal en este caso se refiere a ausencia de Nódulo pulmonar.



**Figura 55.** Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Nódulo y Normal.



**Figura 56.** Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 55.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”




Figura 57. Curva ROC Y AUC en la clasificación entre categoría Nódulo y Normal.

f) Opacidad frente a Normal (no presenta opacidad)

La categoría Normal en este caso se refiere a ausencia de Opacidad.




Figura 58. Matriz de confusión en la evaluación de un clasificador SVM lineal entre categoría Opacidad y Normal.

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”



Figura 59. Ratio de Verdaderos Positivos y de Falsos negativos asociados a la matriz de confusión de la Figura 58.

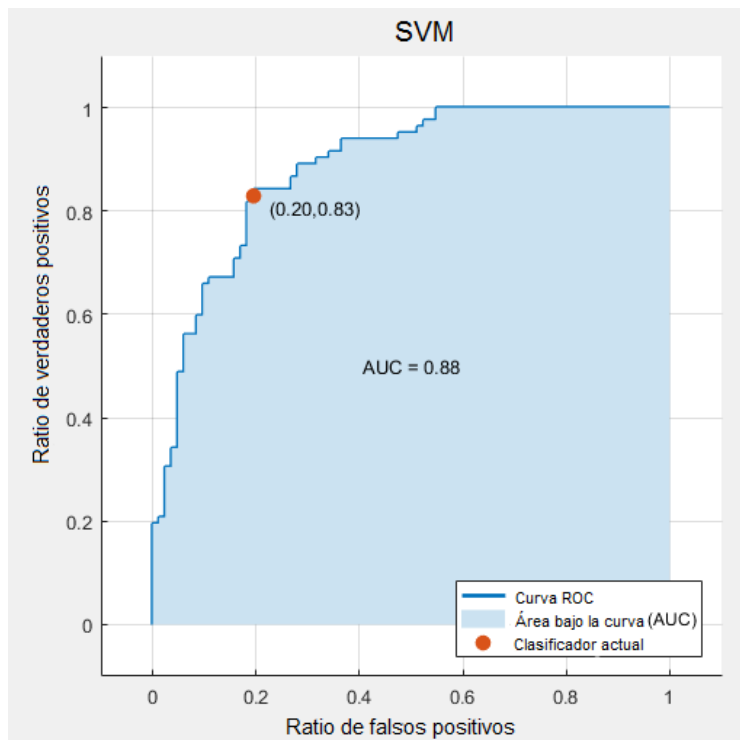


Figura 60. Curva ROC Y AUC en la clasificación entre categoría Opacidad y Normal.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

**Tabla 16.** Índices de rendimiento clínico de todos los clasificadores.

	Anormal vs. Normal	Atelectasis vs. Normal	Cardiomegalia vs. Normal	Efusión pleural vs. Normal	Normal vs. Nódulo	Opacidad vs. Normal
<b>Precisión</b>	82%	82%	87%	80%	82%	82%
<b>Sensibilidad</b>	83%	81%	89%	86%	71%	82%
<b>Esecificidad</b>	80%	83%	85%	75%	92%	80%
<b>AUC</b>	89%	90%	91%	91%	85%	88%
<b>FPR</b>	20%	17%	15%	25%	8%	23%
<b>FNR</b>	17%	19%	11%	14%	29%	20%

### 5.3. VALORACIÓN DE LOS RESULTADOS Y COMPARACIÓN CON OTROS ESTUDIOS

En medicina el acto médico debe estar abalado por estudios que demuestren que el mismo tiene significación estadística, clínica y social. La validez de un test en medicina es el grado en que un test mide lo que se supone que debe de medir. Se obtiene analizando la sensibilidad y la especificidad.

Es evidente que lo ideal sería trabajar con pruebas diagnósticas de alta sensibilidad y especificidad, pero es muy difícil de conseguir. Normalmente, las pruebas de screening en medicina deben presentar una alta sensibilidad para ser capaces de detectar a todos los enfermos. Una prueba muy sensible será especialmente adecuada en aquellos casos en los que el no diagnosticar la enfermedad puede resultar fatal para los enfermos, como ocurre con enfermedades peligrosas pero tratables, como los nódulos de pulmón, o en enfermedades en las que un falso positivo no produzca serios trastornos psicológicos o económicos para el paciente (Morrison et al, 1992).

Por otra parte, la especificidad se refiere, como se señaló previamente, a la probabilidad de que un sujeto sano sea clasificado adecuadamente. En general, las pruebas confirmatorias del diagnóstico deben ser de alta especificidad, para evitar falsos positivos. Las pruebas de alta especificidad son necesarios en enfermedades graves pero sin tratamiento disponible que las haga curables, cuando exista gran interés por conocer la ausencia de enfermedad o cuando diagnosticar a un paciente de un mal que realmente no padece pueda acarrear graves consecuencias, ya sean físicas, psicológicas o económicas (Morrison et al, 1992).

Empezando por la precisión (ACC), el porcentaje de aciertos en la predicción que tiene nuestro sistema, podemos observar (Figura 61) que el mayor valor se obtiene en la separación entre Cardiomegalia y Normal (87%). No obstante, este dato aislado no nos presenta información relevante en el entorno médico, pues debe ir acompañado de índices como la Sensibilidad y la Especificidad, que ponen en evidencia la validación de un test en medicina.

El clasificador que mayor sensibilidad presenta es el que separa entre Cardiomegalia y Normal. Esto se debe a que es una de las condiciones más evidentes en la radiografía de tórax. De esta forma es fácil para el sistema aprender cuales son las características de esta patología y detectarla. Sin embargo, la menor sensibilidad se presenta en el caso que más nos preocupa, el de nódulo de pulmón.

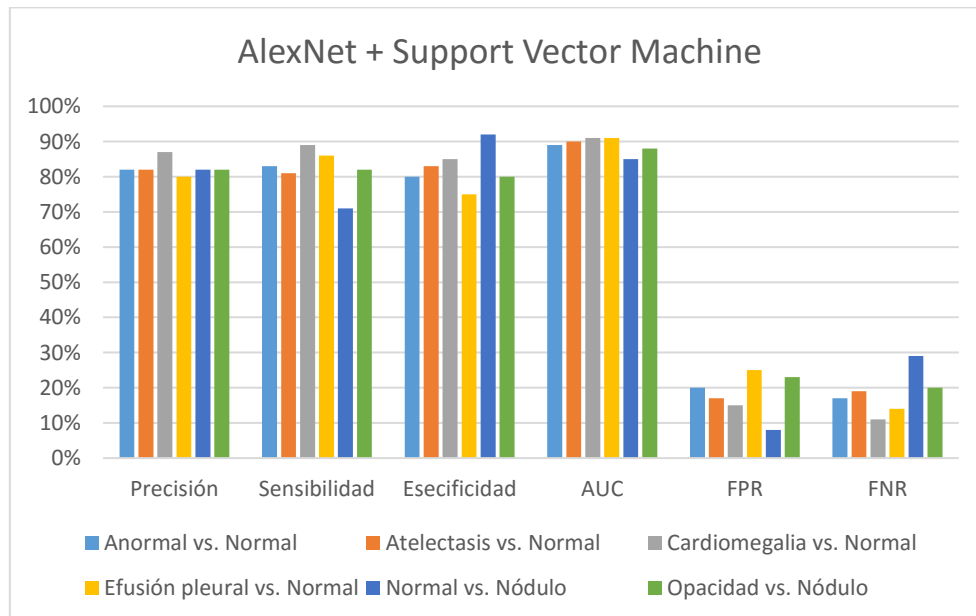
*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Esto se puede deber a un conjunto de datos de imágenes insuficiente para poder extraer características determinantes o a que son alteraciones muy poco evidentes y difíciles de detectar.

En cuanto a la especificidad, el mayor valor se obtiene para el caso de separación entre nódulo y ausencia de patología. Este dato es positivo debido a la gravedad de la enfermedad y a las consecuencias psicológicas que diagnosticar a un paciente con cáncer de pulmón cuando no lo posee podría conllevar.


Comparando el AUC obtenida con estudios previos que llevan a cabo la tarea de una forma muy similar mediante extracción de características con **fc6** usando CNNs (Bar et al, 2013; Bar et al, 2015), ha sido **mejorada o igualada** para los casos de separación entre Anormal vs. Normal, Cardiomegalia vs. Normal y Efusión Pleural vs. Normal obtenidos por Bar et al., (2013) y Bar et al. (2015). No obstante, cabe recalcar que están surgiendo investigaciones que combinan características extraídas con CNNs con características obtenidas manualmente para entrenar clasificadores con resultados satisfactorios.

Además nosotros hemos propuesto tres tareas más de separación (Atelectasia-Normal, Nódulo-Normal, Opacidades-Normal) con bastante relevancia clínica en el diagnóstico y consiguiendo elevados valores de AUC.



**Figura 61.** Comparación de los distintos índices de rendimiento clínico obtenidos en las diferentes tareas de clasificación.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



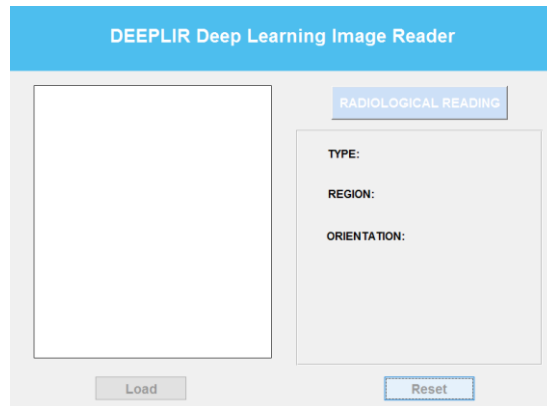
**Figura 62.** Comparación de nuestro proyecto con estudios previos.

**5.4. INTERFAZ GRÁFICA Y EL FUNCIONAMIENTO DEL SISTEMA**

Como se ha explicado en la parte de Material y Métodos, se ha diseñado una interfaz con GUIDE de MATLAB para poder llevar a cabo la interacción con el médico especialista de una forma más fácil y cómoda mostrando la clasificación clara y concisamente. A continuación podemos ver varios de los resultados obtenidos con el sistema:

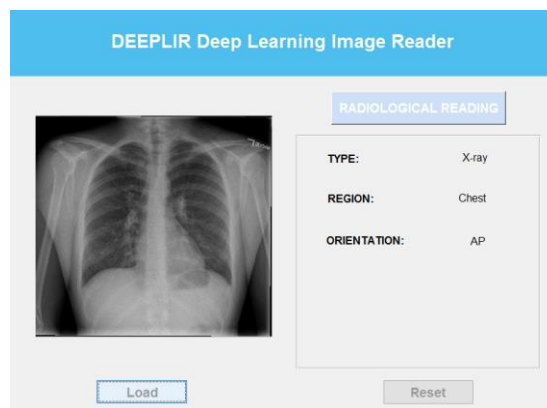
Para empezar a usar el sistema debemos pulsar en Load y cargar una radiografía de tórax PA. Como se desea seguir el procedimiento del informe radiológico real, una vez esta se carga la imagen va a aparecer en Type el tipo (X-Ray), en Region la región (Chest) y en Orientation la orientación (PA). Pese a que nos hemos centrado en capas superiores de clasificación, introduzcamos la imagen que introduzcamos van a aparecer estas categorías. Estas tareas de clasificación podrían ser incluidas en proyectos futuros: ser capaz de distinguir entre el tipo de imagen médica, la región y la orientación.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

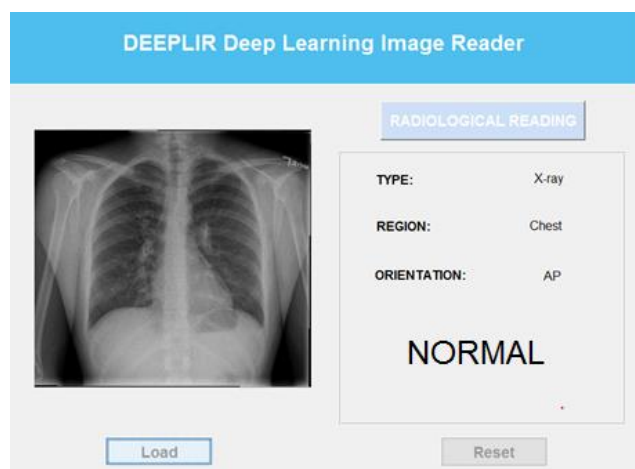


**Figura 63.** Interfaz del sistema antes de ser usada

Una vez se ha cargado la imagen, se pulsa en Radiological Reading. El sistema va a clasificar la radiografía de tórax PA introducida en Normal o Anormal.



**Figura 64.** Imagen de radiografía de tórax PA introducida en el sistema.

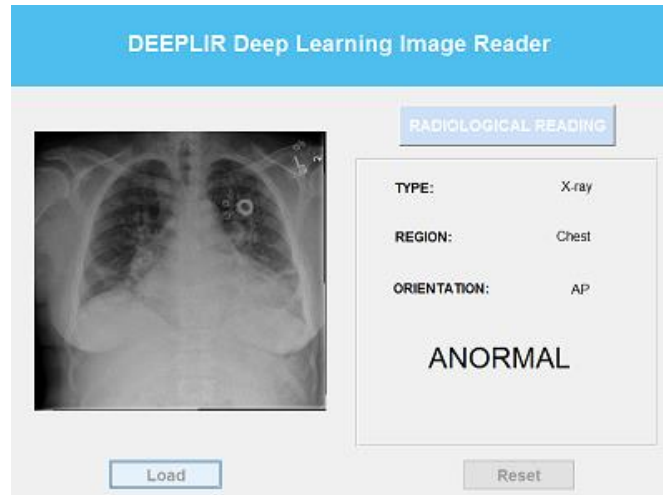


**Figura 65.** Clasificación de la imagen en Normal tras pulsar en Radiológica reading y pasar la imagen por el primer clasificador propuesto.



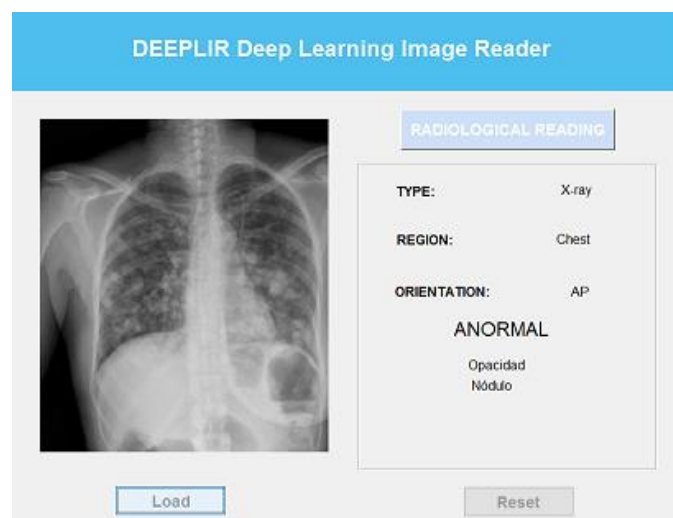
*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

Del mismo modo, el sistema es capaz de detectar de forma correcta tanto imágenes Normales como Anormales.



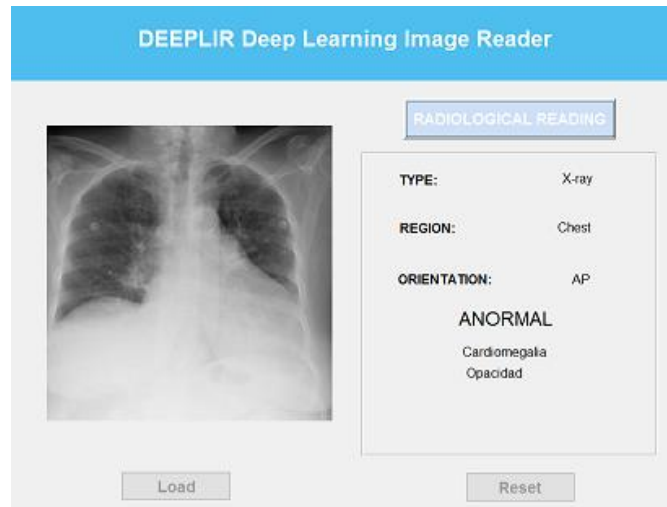
**Figura 66.** Clasificación de la imagen en Anormal tras pulsar en Radiological reading y pasar la imagen por el primer clasificador propuesto.

El sistema no quedó ahí y se fue allá buscando una versión más completa y compleja. Tras pulsar a botón Radiological Reading y pasar la imagen por el clasificador inicial (entre Anormal y Normal), si la categoría determinada era Normal, aparecía la clasificación en pantalla. En caso de que fuera Anormal, salía la categoría Anormal pero además pasaba la imagen por los 5 clasificadores propuestos uno tras otro. Si la clasificación de cada uno de ellos salía normal, la patología no salía por pantalla. Por el contrario, aparecía el nombre o lista de nombres de las posibles patologías.



**Figura 67.** Clasificación de la imagen en Anormal tras pulsar en Radiological reading y pasar la imagen por el sistema final. Primer ejemplo.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*



**Figura 68.** Clasificación de la imagen en Anormal tras pulsar en Radiological reading y pasar la imagen por el sistema final. Segundo ejemplo.

## 5.5. DEMOSTRACIÓN DEL VIDEO COMERCIAL DEL SISTEMA

Por último se ha desarrollado un video comercial que plasma la meta, ya no tan lejana, a alcanzar por nuestro sistema. Se pretende impactar al público con la potencialidad del mismo y ser capaces de obtener financiación para un desarrollo real del producto.

En el video se muestra el funcionamiento del software comercial DeepLIR, desarrollado para este proyecto en el que han querido participar GIBI2<sup>30</sup> y Quibim, donde se carga una imagen y el sistema te indica si se trata de una placa de Rayos X u otro tipo, la región radiografiada, la orientación y si se trata de una radiografía con patología o sana (indicando la enfermedad en caso de hallarla y la probabilidad de pertenecer a esa clase). Todo esto se lleva a cabo mediante inteligencia artificial, pero ya no solo a nivel de clasificación y detección de enfermedades de forma automática, sino además, mediante el control por voz del sistema detectando las preguntas del usuario y respondiendo de acuerdo con el diagnóstico.

Como se puede apreciar a mano derecha, un modulador de voz que se mueve cuando recibe señal de audio de la máquina nos demuestra que se está produciendo la interacción de forma inteligente con el sistema (Classifier Voice).

“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”

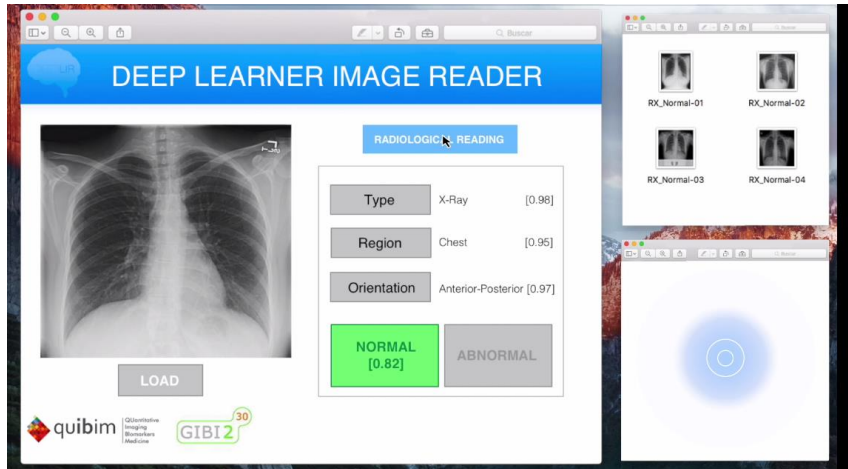


Figura 69. DeepLIR en caso de radiografía de tórax Normal.

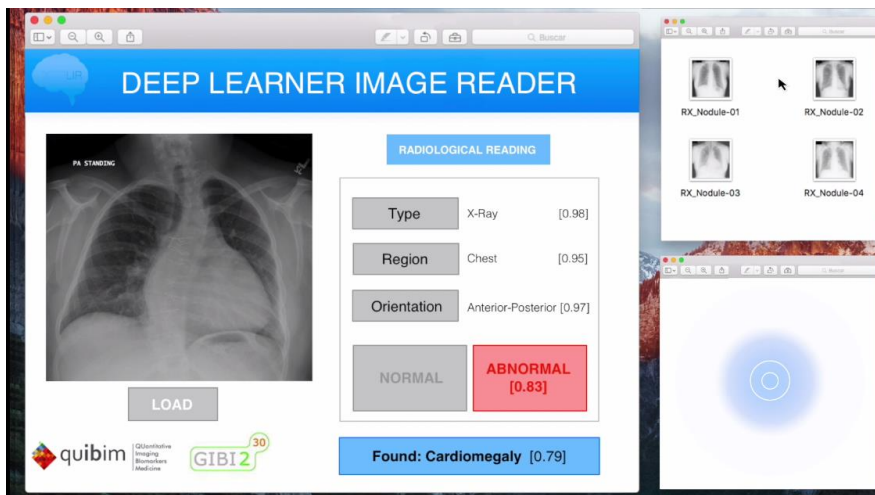


Figura 70. DeepLIR en caso de radiografía de tórax Anormal.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

## **CAPÍTULO 6. CONCLUSIONES Y LÍNEAS FUTURAS**

En este trabajo se pretendía evaluar la efectividad de técnicas de inteligencia artificial en la clasificación de imágenes de rayos X de tórax.

El proyecto ha consistido en la presentación de un sistema de aplicación médica de detección automática de algunas patologías cardiopulmonares. Se ha hecho uso de una red neuronal convolucional preentrenada en imágenes no médicas (ImageNet) como extractor de representaciones jerárquicas de medio y alto nivel de un conjunto de radiografías torácicas posteroanteriores sanas y patológicas.

Pese a la gran diferencia entre las imágenes naturales en las que se ha entrenado la CNN y las radiografías de tórax, se ha llegado a la conclusión de que las redes neuronales convolucionales, y en concreto la que hemos usado, AlexNet, presentan un gran potencial de transferencia de conocimiento tanto a las imágenes de dominio médico como a una gran variedad de nuevas tareas de reconocimiento visual.

La clasificación de radiografías normales y anormales se ha llevado a cabo entrenando varios clasificadores binarios con las características extraídas de forma automática. El mejor rendimiento se ha conseguido con un clasificador SVM. La precisión alcanzada por el mismo ha superado considerablemente la obtenida por los demás clasificadores.

A partir de ahí se han incluido nuevas tareas más específicas de clasificación: diferenciar entre rayos X de tórax sin patología y con alguna en concreto (atelectasia, cardiomegalia, efusión pleural, nódulo pulmonar u opacidades) siguiendo el mismo procedimiento anterior pero centrándonos en modelo SVM que es el que mejor se adapta a esta tarea en concreto. Para proyectos futuros se podría comparar el rendimiento si se extraen características con distintas CNNs preentrenadas. Además se podría incluir la clasificación de diferentes tipos de imágenes médicas, regiones, orientaciones o incluso infinidad de patologías, para desarrollar un sistema lo más completo posible.

Los resultados obtenidos han demostrado que previos experimentos de clasificación de rayos X de tórax normales y anormales llevados a cabo de forma manual (HoG, LBP o SURF) han quedado atrás.

Se ha alcanzado un área bajo la curva ROC de 0.89 en la tarea de separación de rayos X torácicos sanos y patológicos, 0.90 para atelectasia, 0.91 para cardiomegalia, 0.91 entre sanas y efusión pleural, 0.85 para el caso de nódulo pulmonar y 0.88 en opacidades, mejorando el rendimiento obtenido por estudios anteriores (Bar et al, 2013; Bar et al, 2015) que han seguido un procedimiento similar pero con bases de datos mucho más pequeñas. Entrenando y validando al sistema con una base de datos mayor permitiría obtener un mayor rendimiento.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

Es por ello que, con la contribución de distintos hospitales, se propone conseguir una base de datos de rayos X de tórax adecuadamente etiquetada y lo suficientemente grande (del orden de miles de millones de imágenes) para extraer representaciones más precisas, reajustar CNNs para nuestra tarea o incluso llegar a entrenar una red neuronal convolucional desde 0 exclusiva para la clasificación de este tipo de imágenes.

Aunque ya estamos en camino, comparar el rendimiento de la clasificación automática con el de varios radiólogos del Hospital Universitario y Politécnico la Fe podría ser una forma de poder conocer cuánto le falta al sistema propuesto para llegar a presentar una inteligencia artificial igual o superior a la humana. Aunque de momento no se han alcanzado los resultados conseguidos por un especialista con experiencia, con estas técnicas vamos encaminados a hacerlo.

No solo se quiere alcanzar la inteligencia humana a la hora de clasificar imágenes y diagnosticar patologías. Como se ha demostrado en el video, se pretende llegar a interactuar con la máquina mediante la voz, consiguiendo de forma automática y mediante preguntas y respuestas un informe radiológico similar al que hacen hoy en día los radiólogos.

Gracias a la tecnología GPU que ha permitido una aceleración abismal en entrenamiento y predicción se puede concluir en que, a partir de ahora, el deep learning mediante CNNs tiene que ser considerado como el primer candidato en cualquier tarea esencial de reconocimiento visual, y sobre todo en diagnóstico en imagen médica asistido por ordenador.

## **REFERENCIAS**

- Alexnet. MatConvNet VLFeat. <http://www.vlfeat.org/matconvnet/models/beta16/imagenet-caffe-alex.mat> . VLFeat 2016. Consulta realizada: 23/02/2016
- Avni U., Greenspan H., y Goldberger J. (2011). X-ray categorization and spatial localization of chest pathologies. Medical Image Computing and Computer-Assisted Intervention–MICCAI, Springer Berlin Heidelberg, 199-206.
- Avni U., Greenspan H., Konen E., et al. (2011). X-ray categorization and retrieval on the organ and pathology level, using patch-based visual words. IEEE Transactions on Medical Imaging, 30(3), 733-746.
- Bar Y., Diamant I., Wolf L., et al (2013). Deep learning with non-medical training used for chest pathology identification. Tel Aviv: The Blavatnik School of Computer Science.
- Bar Y., Diamant I., Wolf L., et al. (2015). Chest pathology detection using deep learning with non-medical training. Proceedings of IEEE International Symposium on Biomedical Imaging (ISBI).
- Barragán D. (2007). Manual de Interfaz Gráfica de Usuario en Matlab. Extraído: 15 de Abril del 2016 en [https://www.dspace.espol.edu.ec/bitstream/123456789/10740/19/%255Bmatlab%255D\\_MA\\_TLAB\\_GUIDE.pdf](https://www.dspace.espol.edu.ec/bitstream/123456789/10740/19/%255Bmatlab%255D_MA_TLAB_GUIDE.pdf)
- Bayo A., Sánchez I., Melero C. (2005). Guía Práctica de radiología de tórax para atención primaria. Las Matas (Madrid): Adalia Farma, 2005.
- Berlin L. (2000). Pitfalls of the vague radiology report. AJR Am J Roentgenol, 174, 1511-8.
- Carrillo-de-Gea J.M, García-Mateos G. (2010). Detection of Normality/Pathology on Chest Radiographs using LBP, In Bioinformatics, 167-172.
- Coakley FV., Liberman L., Panicek DM. (2003). Style guidelines for radiology reporting: a manner of speaking. AJR Am J Roentgenol, 180, 327-8.
- Csurka G., Dance C., Fan L., et al. (2004). Visual categorization with bags of keypoints. Workshop on statistical learning in computer vision, ECCV, 1(1-22), 1-2.
- CS231n Convolutional Neural Networks for Visual Recognition. Extraído: 12 de Febrero del 2016 en <https://cs231n.github.io/>

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

- De Pablo L. (2003). Técnicas de imagen en patología cardiovascular. Radiología. En: Ruza F, Tratado de cuidados intensivos pediátricos. 3ª edición. Madrid: Ediciones Norma-Capitel, P. 238-240.
- Deng J., Dong W., Socher R., et al. (2009). Imagenet: A large-scale hierarchical image database. In Computer Vision and Pattern Recognition. CVPR 2009. IEEE Conference on, 248-255.
- Deng L., et al. (2013). Deep learning for signal and information processing. Microsoft Research Monograph
- Demner-Fushman D., Kohli M. D., Rosenman M. B., et al. (2015). Preparing a collection of radiology examinations for distribution and retrieval. Journal of the American Medical Informatics Association, page ocv080.
- Demner-Fushman D., Shooshan S.E., Rodriguez L., et al. (2015). Annotation of chest radiology reports for indexing and retrieval. *Multimodal Retrieval in the Medical Domain (MRMD)*.
- Eisen LA., Berger JS., Hegde A., et al. (2006). Competency in chest radiography. A comparison of medical students, residents, and fellows. J Gen Intern Med, 21: 460-5.
- Ellis S.M., Flower C. Ostensen H., et al. (2006). The WHO manual of diagnostic imaging. Radiographic Anatomy and Interpretation of the Chest and the Pulmonary System
- Fawcett T. (2006). An introduction to ROC analysis. Elsevier. Pattern Recognition Letters, 27, 861-874.
- Fernández S., Díaz S. (2003). Pruebas diagnósticas: sensibilidad y especificidad. Unidad de Epidemiología Clínica y Bioestadística. Complejo Hospitalario Universitario A Coruña. 10, 120-124.
- Fleckenstein P., Tanum-Jensen J. (2001) Anatomy in Diagnostic Imaging (3ªed). Chicester, United Kingdom (2014)
- Fraser R.S., Paré P.D. (2002). Derrame Pleural. En R.S. Fraser, P.D. Paré, N. Müller y N. Collman (4ªed.), Diagnóstico de las enfermedades del tórax. Vol IV. (pp. 2722-2730). Madrid: Panamerica.
- Hearst M.A., Dumais S.T., Osman E. (2002). Support Vector Machines. IEE Intelligent Systems. 18-21.
- Herman PG., Hessel SJ. (1975) Accuracy and its relationship to experience in the interpretation of chest radiographs. Invest Radiol, 10: 62-7.
- Herrera A. (2015). Detección de texto utilizando redes neuronales convolucionales. Barcelona: Universitat Politècnica de Catalunya.
- Johns, H.E., Cunningham, J.R. (1983) The Physics of Radiology (Charles C Thomas: Springfield).

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

- Japanese Society of Radiological Technology (JSRT). <http://www.jsrt.or.jp/jsrt-db/eng.php>.
- Krizhevsky A., Sutskever I., Hinton G.E. (2012). Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 25 (NIPS 2012).
- Martí L., Tardáguila F., Bonmatí J. (2004). El informe radiológico: estilo y contenido (II). Radiología. 46, 199- 202.
- Mesh: Medical subject headings. <https://www.nlm.nih.gov/mesh/meshhome.html>.
- Morrison AS. (1992). Screening in Chronic disease. Second edition. New York: Oxford University Press.
- Ojala T., Pietikäinen M., Harwood D. (1996). A comparative study of texture measures with classifications based on featured distributions. Pattern recognition, 29(1), 51-59.
- Oquab M., Bottou L., Laptev I., et al. (2014). Learning and Transferring Mid-Level Image Representations using Convolutional Neural Networks. IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, United States.
- Open-I: An open access biomedical search engine. <https://openi.nlm.nih.gov>
- Pan S., Yang Q. (2010). A survey on transfer learning. IEE transactions on knowledge and data engineering, 22(10).
- Prasoon A., Petersen K., Igel C., Lauze F., et al. (2013). Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. Medical Image Computing and Computer-Assisted Intervention-MICCAI, Springer Berlin Heidelberg, 246-253.
- Rodriguez M.,Martinez A. (2007). El uso de los rayos X en la medicina. Instituto de Física UNAM. Extraído el 8 de Mayo del 2016 en <http://www.smf.mx/boletin/Oct-95/ray-med.html>.
- Razavian A., Azizpour H., Sullivan J., et al. (2014). CNN Features off-the-shelf: an Astounding Baseline for Recognition. Proceedings of the IEE Conference on Computer Vision and Pattern Recognition Workshops. 806-813.
- Shin H., Roberts K., Lu L., Demner-Fushman D., et al. (2016). Learning to Read Chest X-Rays: Recurrent Neural Cascade Model for Automated Image Annotation. Lister Hill National Center for Biomedical Communications, National Library of Medicine. National Institutes of Health, Bethesda, MD, USA.
- Shin H., Holger R., Mingchen G, et al. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. Computer Vision and Pattern recognition.



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

- Stefan J., Alexandros K., Sema C., et al. (2014). Automatic Tuberculosis Screening Using Chest Radiographs. IEE Transactions on Medical Imaging, 33(2), 233-245.
- Swets J. (1988). Measuring the accuracy of diagnostic systems. Science. New Series. 240 (4875), 1285-1293
- Taghizade H., Emami Z., Khademi G., et al. (2016). Tuberculosis: Past, Present and Future. Int J Pediatr. 4(1), 1243-54.
- Tajbakhsh N., Shin J., Suryakanth R., et al. (2016). Convolutional Neural Networks for Medical Image Analysis: Fine Tuning or Full Training. IEEE Transactions on Medical Imaging, 35(5), 1299-1312.
- Tardaguila F., Martí L., Bonmati J. (2004). El informe radiológico: Filosofía general (I). Radiología. 46, 195 -198.
- Urrutia A., Bechini J., Tor J., et al. (2001). Assessment of thoracic X-ray readings by emergency room physicians at a university hospital. Med Clin (Barc), 117, 332-3.
- Valdés P., Morales Á., González I., et al. (2013). El informe de la radiología simple. Algo más que un imperativo legal. Radiología, 55, 279–282.
- Valdés P., Morales Á. (2015) Posición SERAM sobre la necesidad de informar la radiología simple. SERAM.
- Valle S. (2011). Condena penal a dos médicos por no valorar una radiografía. Diario médico. Extraído en 11 de Enero del 2016, de [http://static.diariomedico.com/docs/2011/02/08/dm09\\_02.pdf](http://static.diariomedico.com/docs/2011/02/08/dm09_02.pdf)
- Vargas J. (2013). Aspectos Básicos en Radiología de tórax. En J.G. Soto (3ªed), Manual de diagnóstico y terapéutica en neumología (pp 13-43).
- Visa S., Ramsay B., Ralescu A., et al. (2011). Confusion Matrix-based Feature Selection. Proceedings of The 22nd Midwest Artificial Intelligence and Cognitive Science Conference, 120-127.
- Zeiler M., Fergus R. (2013). Visualizing and Understanding Convolutional Networks. Computer Vision and Pattern Recognition.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

# PRESUPUESTO

## DOCUMENTO II

TRABAJO FIN DE GRADO

**“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”**

Belén Fos Guarinos

Curso 2015-2016

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

## PRESUPUESTO

### 1. OBJETIVO

El documento **PRESUPUESTO** está destinado a reflejar una estimación de la inversión económica que supone el desarrollo de un proyecto ingenieril.

En el presente se va a detallar el presupuesto necesario para alcanzar los objetivos de este Trabajo Fin de Grado expuestos en la Memoria además de las modificaciones presupuestarias que han tenido lugar en el desarrollo real del mismo. En el presupuesto se van a tener en cuenta los costes de personal (trabajo realizado por el personal implicado), de software y de hardware.

### 2. PRESUPUESTO DESGLOSADO

#### 2.1. Costes de personal

El presupuesto de este proyecto proviene principalmente de los gastos de personal, debido a las características del mismo. En este caso, como personal se necesita un ingeniero biomédico para diseñar, desarrollar, implementar y evaluar un sistema de ayuda a la decisión para el radiólogo. En la Tabla 11 se computa el total de horas de dedicación al proyecto por parte del ingeniero. Además se detalla el coste unitario para poder calcular los costes imputables, la cuota patronal y el coste total de personal (también presentes).

**Tabla 17.** Costes de personal necesario para la elaboración del proyecto.

COSTES DE PERSONAL						
PERFIL	JUSTIFICACIÓN Y TAREAS A REALIZAR	COSTE UNITARIO	NÚMERO DE HORAS	COSTE IMPUTABLE (sin cuota patronal)	CUOTA PATRONAL * (37.45%)	COSTE IMPUTABLE TOTAL
Ingeniero biomédico	Diseño, desarrollo, implementación y evaluación de un sistema de ayuda a la decisión para el servicio de radiología	40€/hora *	340 horas	13,600.00 €	5,093.20 €	18,693.20 €
TOTAL						18,693.20 €

\*Los honorarios para un ingeniero según el Colegio Oficial de Ingenieros Industriales de la Comunidad Valenciana (COIICV) son de 40€/hora y la cuota patronal, del 37.45%.

El coste total personal necesario en el proyecto asciende a una cantidad de **dieciocho mil seiscientos noventa y tres con veinte (18693.20 €)**.

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

## 2.2. Costes de software

Las licencias de software necesarias para el desarrollo del presente Trabajo Fin de Grado han sido instaladas en un sistema operativo Microsoft Windows 10 Pro. La licencia del mismo se tiene en cuenta en los costes de software. Además se necesita la licencia de Matlab 2016 con Parallel Toolbox, Neural Network Toolbox y Computer Vision System Toolbox, solamente disponibles para MATLAB R2016a. Para la elaboración de la memoria, de la presentación y de las tablas se necesita el paquete Microsoft Office versión hogar y estudiantes 2013. Podemos observar los costes de estas licencias en la Tabla 12.

**Tabla 18.** Costes de software necesario para la elaboración del proyecto.

COSTES DE SOFTWARE					
PROGRAMA	COSTE TOTAL DE LA LICENCIA (sin IVA)	Nº DE LICENCIAS	PERIODO DE USO	DURACIÓN DE LA LICENCIA	COSTE IMPUTABLE * (SIN IVA)
MATLAB R2016a	2,000.00 €	1	6 meses	1 año	1,000.00 €
MATLAB Parallel Toolbox	1,000.00 €	1	6 meses	1 año	500.00 €
MATLAB Computer Vision System Toolbox	1,000.00 €	1	6 meses	1 año	500.00 €
MATLAB Neural Network Toolbox	1,000.00 €	1	6 meses	1 año	500.00 €
Microsoft Office versión hogar y estudiantes 2013	120.00€	1	6 meses	3 años	20.00 €
Sistema Operativo Microsoft Windows 10 Pro	230.58 €	1	6 meses	3 años	38.43 €
CUDA Toolkit 7.5	0€	1	6 meses	X	0 €
TOTAL					2,558. 43 €

\*Fórmula de cálculo de la amortización:

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

$$\frac{A}{B} \cdot C \cdot D$$

A: número de meses desde la fecha de facturación en que el equipo es utilizado

B: periodo de amortización

C: coste del equipo (sin IVA)

D: % del uso que se dedica al proyecto

El coste total de software necesario en el proyecto asciende a una cantidad de **dos mil quinientos cincuenta y ocho con cuarenta y tres euros (3095.70 €)**.

### 2.3. Costes de hardware

Para el desarrollo del proyecto se ha necesitado un único Servidor de las siguientes características: Core i7, 64 Gb RAM y una tarjeta gráfica. En este caso se ha usado la Tesla K-40, que ha sido proporcionada por NVIDIA por tratarse de un proyecto de investigación en el que se maneja una cantidad considerable de imágenes con fines biomédicos. Se presentó una propuesta del proyecto a desarrollar y fue aceptada la propuesta, proporcionándonos la GPU. Aun así será considerada como inversión en el proyecto.

**Tabla 19.** Costes de hardware necesario para la elaboración del proyecto.

COSTES DE HARDWARE					
DESCRIPCIÓN	COSTE TOTAL DEL EQUIPO (sin IVA)	UNIDADES	PERIODO DE AMORTIZACIÓN	PERIODO DE USO	COSTE IMPUTABLE * (SIN IVA)
Server (Core i7, 64 Gb RAM):	1,500.00 €	1	3 años	6 meses	250.00€
Tarjeta GPU Tesla K-40:	2,980.00 €	1	3 años	6 meses	496.00 €
TOTAL					746.00 €

\*Fórmula de cálculo de la amortización:

$$\frac{A}{B} \cdot C \cdot D$$

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

A: número de meses desde la fecha de facturación en que el equipo es utilizado

B: periodo de amortización

C: coste del equipo (sin IVA)

D: % del uso que se dedica al proyecto

El coste total de hardware necesario en el proyecto asciende a una cantidad de **setecientos cuarenta y seis euros (746.00 €)**.

### 3. PRESUPUESTOS TOTAL DEL PROYECTO

Para obtener el presupuesto total del proyecto vamos a calcular el presupuesto de ejecución que es la suma de los costes totales de personal, software y hardware necesitados en el proyecto. El presupuesto de contrata es la suma del presupuesto de ejecución más los gastos generales de empresa (13%) el beneficio industrial (6%) y el IVA (21%).

Los gastos generales son los que el contratista tiene por el hecho de ejercer una actividad empresarial y que son distintos de los costes de ejecución. Pero no solo se deben tener en cuenta los costes de ejecución y los gastos generales, puesto que de esta forma el contratista no estaría ganando nada por la ejecución del proyecto. Para ello se debe añadir el beneficio industrial.

De esta forma, obtenemos el presupuesto total, desglosado en la Tabla 14.

**Tabla 20.** Presupuesto total del proyecto desglosado.

RESUMEN DEL PROYECTO (CON IVA Y CUOTA PATRONAL INCLUIDOS)	
Coste total de personal	18,693.20 €
Coste total de hardware	2,558.43 €
Coste total de software	746.00 €
<b>Total del presupuesto de Ejecución</b>	<b>21,997.63 €</b>
Gastos generales (13%)	2,859.69 €
Beneficio Industrial (6%)	1,319.86 €
<b>Total</b>	<b>26,177.18 €</b>
IVA (21%)	5,497.21 €
<b>TOTAL PRESUPUESTO</b>	<b>31,674.00 €</b>

El presupuesto total del proyecto asciende a una cantidad de **treinta y uno mil seiscientos setenta y cuatro euros (31674 €)**

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

# ANEXOS

## DOCUMENTO III

TRABAJO FIN DE GRADO

**“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”**

Belén Fos Guarinos

Curso 2015-2016

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

En los Anexos se adjunta parte del código que no se ha explicado y detallado durante la memoria. El que sí que se ha ido explicando aunque solo sea de forma general no se adjunta en los Anexos. Además esta parte se incluye el Abstract aceptado para ESOI/EUSOMII sobre el proyecto para una Comunicación Oral en octubre.

## 1. PROGRAMA CON PYTHON

Programa en Python para estructurar la base de datos, extrayendo la información del código JSON de la página de Open-I que relaciona los términos del MeSH con el nombre de la imagen, para poder clasificar las imágenes en carpetas según la patología presente, en caso de que la haya.

```
#!/usr/bin/python
import urllib, json
import os
import re
import shutil

variable='1'
variable2='100'

for p in range(1,7500,100):

    imagenes=[]
    MeSHes=[]
    imag=[]
    normal=[]
    anormal=[]
    et=[]

    url =
"https://openi.nlm.nih.gov/retrieve.php?query=&it=xg&coll=cxr&m="+variable+"&n="+variabl
e2

    response = urllib.urlopen(url)
    data = json.load(response)

    lista=data['list']
    contador=-1
    for l in lista:
        contador=contador+1
        imagen=data['list'][contador]['imgThumb']
```



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
imagen=imagen.replace('.png','')
imagen=list(imagen)
posicion=imagen.index('R')
imagen[0:posicion+1]=[]
imagen=''.join(imagen)
MeSH = data['list'][contador]['MeSH']['major']
imagenes.append(imagen)
MeSHes.append(MeSH)
contador--1
for j in imagenes:
    contador=contador+1
    im=str(imagenes[contador])
    imag.append(im)

x=[]
final=[]
contador--1
for i in MeSHes:
    contador=contador+1
    etiqueta=MeSHes[contador]
    cont--1
    for j in etiqueta:
        cont=cont+1
        et=etiqueta[cont].split('/')
        et=et+x
        x=et
    final.append(x)
    x=[]

    if 'normal' in final[contador]:
        normal.append(imag[contador]+' .jpg')
    else:
        anormal.append(imag[contador]+' .jpg')

contador--1
for n in normal:
    contador=contador+1
    foto=normal[contador]
    try:
        src="../../Desktop/X/%s" %foto
        dst="../../Desktop/Normal"
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
        shutil.move(src,dst)
    except:
        print foto, 'No encontrada\n'
contador=-1
for a in anormal:
    contador=contador+1
    foto=anormal[contador]
    try:
        src="../../../Desktop/X/%s" %foto
        dst="../../../Desktop/Anormal"
        shutil.move(src,dst)
    except:
        print foto, 'No encontrada\n'

variable=int(variable)+100
variable=str(variable)
variable2=int(variable2)+100
variable2=str(variable2)
```

## 2. PRIMERA VERSIÓN DEL SISTEMA CON MATLAB (GUIDE)

Primera versión del sistema, que lleva a cabo la clasificación entre radiografías de tórax anteroposteriores Normales y Anormales. FIN.mat contiene todos los clasificadores entrenados a lo largo de todo el proyecto.

```
function varargout = interfaz2(varargin)
% INTERFAZ2 MATLAB code for interfaz2.fig
%   INTERFAZ2, by itself, creates a new INTERFAZ2 or raises the existing
%   singleton*.
%
%   H = INTERFAZ2 returns the handle to a new INTERFAZ2 or the handle to
%   the existing singleton*.
%
%   INTERFAZ2('CALLBACK',hObject,eventData,handles,...) calls the local
%   function named CALLBACK in INTERFAZ2.M with the given input
arguments.
%
%   INTERFAZ2('Property','Value',...) creates a new INTERFAZ2 or raises
the
%   existing singleton*. Starting from the left, property value pairs
are
%   applied to the GUI before interfaz2_OpeningFcn gets called. An
%   unrecognized property name or invalid value makes property
application
%   stop. All inputs are passed to interfaz2_OpeningFcn via varargin.
%
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
%      *See GUI Options on GUIDE's Tools menu.  Choose "GUI allows only one
%      instance to run (singleton)".
%
% See also: GUIDE, GUIDATA, GUIHANDLES

% Edit the above text to modify the response to help interfaz2

% Last Modified by GUIDE v2.5 31-Aug-2016 09:57:09

% Begin initialization code - DO NOT EDIT
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',  gui_Singleton, ...
                  'gui_OpeningFcn', @interfaz2_OpeningFcn, ...
                  'gui_OutputFcn',  @interfaz2_OutputFcn, ...
                  'gui_LayoutFcn',  [] , ...
                  'gui_Callback',    []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
% End initialization code - DO NOT EDIT

% --- Executes just before interfaz2 is made visible.
function interfaz2_OpeningFcn(hObject, eventdata, handles, varargin)
% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% varargin   command line arguments to interfaz2 (see VARARGIN)

% Choose default command line output for interfaz2
handles.output = hObject;
handles.myImage=[];
handles.data=load('FIN.mat'); % Incluye todos los clasificadores ya
entrenados
handles.label=[];
% Update handles structure
guidata(hObject, handles);

% UIWAIT makes interfaz2 wait for user response (see UIRESUME)
% uiwait(handles.figure1);

% --- Outputs from this function are returned to the command line.
function varargout = interfaz2_OutputFcn(hObject, eventdata, handles)
% varargout  cell array for returning output args (see VARARGOUT);
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
% handles      structure with handles and user data (see GUIDATA)

% Get default command line output from handles structure
varargout{1} = handles.output;

% --- Executes on button press in pushbutton1.
function pushbutton1_Callback(hObject, eventdata, handles)
% hObject      handle to pushbutton1 (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)
try
    [filename,pathname]=uigetfile('*.jpg','Seleccione imagen a
clasificar');
    if isequal(filename,0)
        else
            handles.myImage=imread(fullfile(pathname, filename));
        end
        guidata(hObject,handles);
catch
    msgbox('Error')
end
imshow(handles.myImage)
axis off;
set(handles.text7,'String','X-ray');
set(handles.text8,'String','Chest');
set(handles.text9,'String','AP');

% --- Executes on button press in pushbutton2.
function pushbutton2_Callback(hObject, eventdata, handles)
% hObject      handle to pushbutton2 (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)
I=handles.myImage;
if ismatrix(I)
    I = cat(3,I,I,I);
end
Iout = imresize(I, [227 227]);
I=Iout;
convnet=handles.data.convnet;
featureLayer=handles.data.featureLayer;
classifier=handles.data.classifier_anormal_normal_SVM.ClassificationSVM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)

if label=='Normal'
    set(handles.text6,'String',char(label)); %modificar
else
    set(handles.text6,'String',char(label)); %modificar
end

% --- Executes on button press in pushbutton3.
function pushbutton3_Callback(hObject, eventdata, handles)
% hObject      handle to pushbutton3 (see GCBO)
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
axes(handles.axes1);
cla reset;
set(gca, 'Box', 'on');
set(gca, 'XTick', [], 'Ytick', []);
set(handles.text7, 'String', [])
set(handles.text8, 'String', [])
set(handles.text9, 'String', [])
```

### 3. IMPLEMENTACIÓN FINAL DEL SISTEMA (GUIDE)

Implementación final del sistema, que lleva a cabo la clasificación entre radiografías de tórax anteroposteriores Normales y Anormales. En el caso de que sean Anormales, predice además si está presente alguna de las 5 patologías presentadas. FIN.mat contiene todos los clasificadores entrenados a lo largo de todo el proyecto.

Simplemente se incluyen las modificaciones realizadas sobre el anterior en el pushbutton2 y pushbutton3.

```
% --- Executes on button press in pushbutton2.
function pushbutton2_Callback(hObject, eventdata, handles)
% hObject handle to pushbutton2 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
I=handles.myImage;
if ismatrix(I)
    I = cat(3,I,I,I);
end
Iout = imresize(I, [227 227]);
I=Iout;
convnet=handles.data.convnet;
featureLayer=handles.data.featureLayer;
classifier=handles.data.classifier_anormal_normal_SVM.ClassificationSVM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)

if label=='Normal'
    set(handles.text6, 'String', char(label)); %modificar
else
    set(handles.text6, 'String', char(label)); %modificar

classifier=handles.data.classifier_atelectasis_normal_SVM.ClassificationSVM
;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)
if label=='Normal'
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
        set(handles.text11, 'String', []); %modificar
    else
        set(handles.text11, 'String', char(label)); %modificar
    end

classifier=handles.data.classifier_cardiomegalia_normal_SVM.ClassificationS
VM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)
if label=='Normal'
    set(handles.text12, 'String', []); %modificar
else
    set(handles.text12, 'String', char(label)); %modificar
end

classifier=handles.data.classifier_efusion_normal_SVM.ClassificationSVM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)
if label=='Normal'
    set(handles.text13, 'String', []); %modificar
else
    set(handles.text13, 'String', char(label)); %modificar
end

classifier=handles.data.classifier_nodule_normal_SVM.ClassificationSVM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)
if label=='Normal'
    set(handles.text14, 'String', []); %modificar
else
    set(handles.text14, 'String', char(label)); %modificar
end

classifier=handles.data.classifier_opacidad_normal_SVM.ClassificationSVM;
imageFeatures=activations(convnet,I,featureLayer);
[label,score]=predict(classifier,imageFeatures)
if label=='Normal'
    set(handles.text15, 'String', []); %modificar
else
    set(handles.text15, 'String', char(label)); %modificar
end

end

% --- Executes on button press in pushbutton3.
function pushbutton3_Callback(hObject, eventdata, handles)
% hObject    handle to pushbutton3 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
axes(handles.axes1);
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

```
cla reset;  
set(gca, 'Box', 'on');  
set(gca, 'XTick', [], 'Ytick', []);  
set(handles.text7, 'String', [])  
set(handles.text8, 'String', [])  
set(handles.text9, 'String', [])  
set(handles.text6, 'String', [])  
set(handles.text11, 'String', [])  
set(handles.text12, 'String', [])  
set(handles.text13, 'String', [])  
set(handles.text14, 'String', [])  
set(handles.text15, 'String', [])
```

*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

#### 4. ABSTRACT PARA ESOI/EUSOMII

A continuación se adjunta el abstract presentado para ESOI/EUSOMII sobre el proyecto, que ha sido aceptado para llevar a cabo una comunicación oral en el próximo congreso de octubre en el Hospital Universitario y Politécnico La Fe de Valencia.

**Title:** Deep Learning applied to automated Chest X-Ray screening.

**Author(s):** Belén Fos-Guarinos, Ángel Alberich-Bayarri, Ignacio Bosch-Roig, Amadeo Ten-Esteve, Luis Martí-Bonmatí

**Topic:** Artificial intelligence techniques applied to medical imaging.

**Purpose:** One of the most commonly performed examination by radiologists is chest radiography, providing information of the most important anatomical structures of the body. This non-invasive medical checkup is essential to face with diverse respiratory alterations associated with a high mortality rate, as they show a wide range of potential information. Human eye of radiologists is greatly precise and has been highly trained over the last years. However, when medical images are used to diagnose chest diseases, there are certain changes that are very subtle (pixel level) and remain hidden from visual interpretation.

Recently, new techniques based on artificial intelligence concepts have emerged in the field of Computer Vision. We propose to use deep learning techniques, especially Convolutional Neural Networks (CNN) in a computer aided diagnostic (CAD) system to help radiologists to perform automated screening of chest radiographs.

**Methods and Materials:** A database of chest X-ray images (7470 radiographs) from the Indiana University and available to use at the Open-I platform was used for the study. A subset of cases was selected consisting of 2242 A-P chest x-ray images divided in different groups (normal vs abnormal, cardiomegaly vs normal, nodule vs normal, opacity vs normal, atelectasis vs normal and pleural effusion vs normal). The AlexNet CNN (pretrained with ImageNet) was implemented in Matlab to extract features from the different groups and use them to train a Support Vector Machine classifier. An NVIDIA Tesla K40 GPU was used to optimize the computing performance.

**Results:** A software tool was successfully implemented to help the radiologist to distinguish between healthy and abnormal chest x-ray obtaining an area under curve (AUC) of 0.86, 0.91 for cardiomegaly vs. normal ones, 0.92 between healthy and pleural effusion, 0.70 for nodule vs. normal ones, 0.90 for atelectasis group and 0.86 for opacity.



*“Diseño de técnicas de inteligencia artificial aplicadas a imágenes médicas de rayos X para la detección de estructuras anatómicas de los pulmones y sus alteraciones”*

---

**Conclusion:** Using a pretrained CNN (learned from non-medical datasets, ImageNet) as an automatically feature extractor for training a SVM classifier is a good approach to get relevant results in chest X-ray screening tasks and in the detection of pathologies. Future works could be directed towards fine-tuning a CNN with larger X-ray datasets to improve the performance or extracting features taking as images segmented lung patches to be more precise in lung pathologies and go deeper in the detail.