

Aplicación de la inteligencia artificial (IA) en imagen médica durante la crisis del Covid-19: Un estudio de caso de *Deep Learning* como invención del "Método de Invención" *

Aplicação da inteligência artificial (IA) em imagens médicas durante a crise Covid-19: Um estudo de caso do Deep Learning como uma invenção do "Método da Invenção"

Application of artificial intelligence (AI) in medical imaging during the Covid-19 crisis: A case study of Deep Learning as an invention of the "Method of Inventing"

Juan Franco**

1

Resumen:

En este artículo se pretende estudiar la aplicación de la inteligencia artificial (IA) en imagen médica para el diagnóstico de Covid-19 durante la crisis de la pandemia, abordando un estudio de caso de Deep Learning como invención del "método de invención". En comparación con las técnicas utilizadas hasta ahora para el desarrollo de software de diagnóstico de imágenes médicas, caracterizadas por la fuerte interacción entre médicos y desarrolladores informáticos, orientadas a convertir los atributos de la imagen, en elementos sistematizados y parametrizados para reflejar el estado de conocimiento alrededor del área de diagnóstico; el nuevo método basado en Deep Learning, está orientado a clasificar las imágenes y generar un diagnóstico directamente desde los datos mismos, prescindiendo en gran medida, de la interacción referida entre expertos. Frente a la necesidad y relevancia de la disponibilidad de datos etiquetados, que pueden afectar a diferentes campos del diagnóstico médico, en el caso de estudio se evidenció un entorno favorable de cooperación y acceso a bases de datos con imágenes médicas etiquetadas, como condición probablemente asociada a la movilización institucional, social y política alrededor de la pandemia.

Palabras clave: Innovación, Inteligencia Artificial, *Deep Learning*, imágenes médicas, Covid-19

* Recepción del artículo: dd/mm/aaaa. Entrega de la Evaluación Final: dd/mm/aaaa

** Juan Franco Quintero. Estudiante TFM, Máster Universitario en Estudios de la Ciencia, la Tecnología y la Innovación. Universitat Politècnica de València (UPV). Correo electrónico: juafra@posgrado.upv.es

Resumo:

Este artigo tem como objetivo estudar a aplicação da inteligência artificial (IA) em imagens médicas para o diagnóstico de Covid-19 durante a crise pandêmica, abordando um estudo de caso de Deep Learning como uma invenção do “método de invenção”. Em comparação com as técnicas até agora utilizadas para o desenvolvimento de software de diagnóstico por imagem médica, caracterizado pela forte interação entre médicos e programadores informáticos, visa converter os atributos da imagem em elementos sistematizados e parametrizados para refletir o estado de conhecimento em torno da área de diagnóstico; o novo método baseado em Deep Learning visa classificar as imagens e gerar um diagnóstico diretamente a partir dos próprios dados, dispensando em grande medida a referida interação entre especialistas. Diante da necessidade e relevância da disponibilidade de dados rotulados, que podem afetar diferentes campos do diagnóstico médico, o estudo de caso mostrou um ambiente favorável de cooperação e acesso a bancos de dados com imagens médicas rotuladas, condição provavelmente associada à mobilização institucional, social e política em torno da pandemia.

Palavras-chave: Inovação, inteligência artificial, *Deep Learning*, imagens médicas, Covid-19

Abstract:

This article aims to study the application of artificial intelligence (AI) in medical imaging for the diagnosis of Covid-19 during the pandemic crisis, addressing a case study of Deep Learning as an invention of the “invention method”. Compared with the techniques used up to now for the development of medical imaging diagnostic software, characterized by the strong interaction between doctors and computer developers, aimed at converting the image attributes into systematized and parameterized elements to reflect the state of knowledge around the diagnostic area; the new method based on Deep Learning is aimed at classifying the images and generating a diagnosis directly from the data itself, largely dispensing with the interaction referred to between experts. Faced with the need and relevance of the availability of labeled data, which can affect different fields of medical diagnosis, the case study showed a favorable environment of cooperation and access to databases with labeled medical images, as a condition that is probably associated to the institutional, social and political mobilization around the pandemic.

Key words: Innovation, artificial intelligence, *Deep Learning*, medical imaging, Covid-19

Introducción

La inteligencia artificial puede aumentar considerablemente la eficiencia de la economía existente. Pero puede tener un impacto aún mayor al servir como un nuevo "método de invención" de propósito general que puede remodelar la naturaleza del proceso de innovación y la organización de la I + D (Cockburn, Henderson y Stern, 2018).

El poder transformador de la IA radica en su capacidad de revolucionar nuestra forma de inventar y de pensar. Desde una nueva perspectiva, los autores referidos consideran los desarrollos de redes neuronales y el aprendizaje automático (*Machine Learning* y *Deep Learning*), y su interacción, como la "invención de un método de invención".

El creciente número de usos de la IA, y sobre todo, su acelerado y fuerte impacto sobre múltiples áreas de generación de conocimiento científico y desarrollo tecnológico, ha determinado que en muchos casos, los resultados de su aplicación sean calificados como una nueva revolución o la reinención de cada área objeto de disrupción.

Según Rotman (2019), cada vez cuesta más hacer investigación básica en I+D porque la ciencia es cada vez más compleja. Es allí donde la inteligencia artificial sobresale como una tecnología capaz de abordar este reto, ahorrando tiempos y costes en todas las partes del proceso e impulsando formas de pensar totalmente nuevas.

Teniendo en cuenta que cada vez existen más avances significativos en el uso de la IA, lo cual a su vez tiende a reforzar las expectativas y a sobrevalorar sus impactos potenciales a corto y mediano plazo, se hace necesario el desarrollo de estudios orientados a entender cómo influirá la IA en el futuro del proceso de innovación. Desde esta perspectiva, el trabajo de Cockburn, Henderson y Stern, (2018) señala que la inteligencia artificial agrupa tres áreas diferenciadas de acción: *sistemas de símbolos, robótica y redes neuronales*; cada una de las cuales difiere en su potencial para ser una Tecnología de Propósito General (GPT – *General Purpose Technology*), o una Invención en el Método de Invención (IMI – *Invention in the Method of Inventing*), o ambos. Específicamente, dentro de las redes neuronales, las técnicas de *Deep Learning* (DL), afirman los autores, tienen el potencial de transformar los procesos de innovación, bien sea como GPT, IMI o ambas.

Conceptualmente, el alcance del trabajo de Cockburn, Henderson y Stern (2018) hace referencia a lo que se ha denominado la Invención de un Método de Invención, modelado por la incorporación de herramientas de investigación basadas en la IA. La introducción de dichas herramientas de IA, en este caso *Deep Learning*, tiene el potencial de generar cambios profundos en los procesos de innovación y en los métodos de I+D aplicados; modificando radicalmente, las operaciones, interacciones y recursos de los métodos predecesores, en modos y tiempos, configurando en consecuencia, un nuevo proceso de invención.

Dicho trabajo aborda el estudio del impacto de la inteligencia artificial sobre la innovación y establece que conducirá hacia una "sustitución significativa de la investigación intensiva en mano de obra más rutinaria hacia una investigación que aproveche la interacción entre grandes conjuntos de datos generados pasivamente y algoritmos de predicción mejorados" (2018 : 2). Es decir, un avance conceptual que en el futuro marcará una transición hacia la automatización de la investigación como resultado del nuevo método de invención.

Aunque no se ha llegado (todavía) a la invención de un método de invención generado por la IA, de manera autónoma, sí se evidencia un factor disruptivo como resultado de la aplicación dirigida de la IA, desde su estado de arte actual.

Desde este enfoque, Kim (2020) intenta una aproximación a cómo la IA “genera de manera autónoma las invenciones”, y de qué manera las invenciones “generadas por la IA” se diferencian de las invenciones “desarrolladas con la ayuda de la IA”, aspectos que sin duda, incidirán en el debate sobre el futuro de la ley y la política de patentes. Si bien existe un consenso general de que tales inventos son incompatibles con el concepto de inventores humanos, sigue sin estar claro en qué medida se pueden justificar, las preocupaciones con respecto a la falta de autenticidad “no humana”.

Además, menciona que las redes neuronales artificiales y los algoritmos evolutivos, los tipos de IA más debatidos en la literatura sobre el derecho de patentes, requieren instrucciones detalladas para establecer cómo se deriva la relación entre entradas y salidas a través del cálculo. Por lo anterior, se señala que, mientras las computadoras utilicen instrucciones definidas por un humano sobre cómo resolver un problema, la separación entre el ingenio humano y el no humano (algorítmico) seguirá siendo en sí misma, artificial.

El presente trabajo pretende abordar el estudio de la aplicación de la inteligencia artificial (IA) en imagen médica para el diagnóstico de Covid-19 durante la crisis de la pandemia, a partir de un estudio de caso. En tal sentido, se busca hacer una aplicación del análisis general presentado por Cockburn, Henderson y Stern (2018), identificando aquellos elementos que permiten evidenciar y describir la disrupción del *Deep Learning* como “método de invención”, para el caso específico de estudio.

4

En función de la naturaleza del caso analizado, se utilizó la entrevista como técnica de recolección de datos. Sin embargo, debido a las dificultades para acceder a interlocutores de alto nivel y desarrolladores de *Deep Learning*, en una época de crisis determinada por el Covid-19, se determinó la necesidad de aplicar, de manera complementaria, la técnica de análisis de contenidos de distintos trabajos de investigación publicados sobre el área de estudio, con el propósito de contrastar diferentes fuentes y modos de aproximación.

1. El *Deep Learning* como herramienta de investigación e invención

1.1. El *Deep Learning* en imagen médica

Actualmente, se están aplicando diferentes técnicas de *Deep Learning* o Aprendizaje Profundo en el procesamiento y clasificación de imágenes médicas, como herramienta para la predicción y diagnóstico médico.

Existen diferentes trabajos y artículos que describen diferentes aplicaciones de Deep Learning en imagen médica. Un trabajo reciente realizado por Chanampe y otros (2019), apuntó a utilizar técnicas *Deep Learning* para clasificar distintos tipos de lesiones de ecografías mamarias, realizando al mismo tiempo una descripción del estado del arte de las arquitecturas de *Deep Learning* en la clasificación de imágenes y sus distintas estrategias de funcionamiento. Así mismo, mediante el uso de Redes Neuronales Convolucionales Profundas (DCNN) desarrollaron un modelo que permite clasificar diferentes tipos de lesiones, que alcanzó a lograr una precisión del 62%, sobre la base de datos mini-MIAS.

De acuerdo con Lecun, Bengio y Hinton (2015), los métodos de *Deep Learning* han mejorado drásticamente el estado del arte en reconocimiento del habla, reconocimiento de objetos visuales, detección de objetos y muchos otros dominios, como el descubrimiento de fármacos y la genómica. Así mismo indican que la aplicación de las DCNN, como uno de los métodos de *Deep Learning* empleado para el análisis de imágenes, está orientado a descubrir las características en las imágenes, como detección de bordes y esquinas hasta llegar a detectar características más complejas, a través del entrenamiento con grandes conjuntos de datos.

Conceptualmente, los citados autores señalan que el aprendizaje profundo permite la construcción de modelos computacionales compuestos por múltiples capas de procesamiento para aprender representaciones de datos con múltiples niveles de abstracción. En tal sentido, el aprendizaje profundo permite descubrir una estructura compleja en grandes conjuntos de datos, mediante el uso del algoritmo de retro-propagación para indicar cómo una máquina debe cambiar sus parámetros internos que se utilizan para calcular la representación en cada capa de la representación en la capa anterior.

Otra aplicación es presentada por Nahid y otros (2020), quienes presentan un nuevo método para identificar neumonía mediante el análisis de radiografía de tórax, empleando una red convolucional multicanal. El método ha sido probado en un amplio conjunto de datos de radiografía de tórax, y los resultados indican que es un modelo altamente preciso en la detección, que puede ser empleado en un esquema de diagnóstico automático de neumonía.

Civit-Masot y otros, (2020) mencionan que el estudio de imágenes médicas ha experimentado un gran avance con la aplicación de sistemas de *Machine Learning*, capaces de extraer de manera automática, las características necesarias para realizar diagnósticos y predicciones correctas. Además, en los últimos años esta tecnología ha evolucionado hasta una rama concreta conocida como *Deep Learning*.

5

Las diferencias entre *Machine Learning* y *Deep Learning* pueden ser definidas del siguiente modo:

“Mientras que en *Machine Learning* el usuario le da al sistema una gran cantidad de reglas para resolver el problema, en *Deep Learning* el usuario le da al sistema un modelo de red y solo unas pocas instrucciones para modificar el modelo cuando ocurren errores. Por lo tanto, al usar *Deep Learning*, es más fácil y rápido capacitar sistema de clasificación”. (Civit-Masot y otros, 2020 : 2)

1.2. El *Deep Learning* aplicado al diagnóstico de Covid-19

De acuerdo con González (2020), desde que en el mes de Enero de 2020, el Comité de Emergencias de la Organización Mundial de la Salud (OMS) declaró la situación desencadenada por la Covid-19 como una emergencia de salud pública de importancia internacional (ESPII), las investigaciones científicas relacionadas con el coronavirus SARS-CoV-2 se multiplicaron de manera extraordinaria, no solo en número, sino también en la rapidez de reacción frente a una circunstancia excepcional.

En tal sentido, se ha evidenciado una gran movilización política, económica y social, orientada a controlar la pandemia, todo lo cual ha inducido una respuesta masiva del personal científico y técnico, así como su articulación interinstitucional, con el propósito de contribuir a la generación de soluciones desde sus respectivas áreas de conocimiento.

Panwar y otros (2020), señalan que uno de los métodos más comunes y efectivos aplicados por los investigadores es el uso de tomografías computarizadas y rayos X para analizar las imágenes de los pulmones en el diagnóstico de Covid-19. Sin embargo, la inspección manual de cada informe requiere la participación de varios especialistas en radiología y tiempo.

Lo anterior, ha motivado el desarrollo de diversas iniciativas y trabajos orientados a construir modelos que utilizan *Deep Learning* para identificar y clasificar imágenes médicas en el diagnóstico rápido de Covid-19.

Algunos proyectos, principalmente desarrollados por empresas e iniciativas privadas especializadas en aplicaciones y desarrollos informáticos o biomédicos, han difundido sus resultados y las herramientas creadas, muchas de ellas de libre acceso para la comunidad médica, a través de sus páginas web, redes sociales o reportajes periodísticos en medios de comunicación.

Adicionalmente, se identifican numerosas iniciativas basadas en mecanismos de cooperación interinstitucional entre institutos de investigación, universidades y agencias gubernamentales. En muchos casos, con proyectos de participación transnacional

A pesar del corto tiempo transcurrido, se evidencia un número considerable de publicaciones técnicas y científicas, algunas de ellas indexadas, y numerosos artículos de difusión en medios de comunicación, portales web y redes sociales, que hacen referencia a diferentes proyectos de aplicación de *Deep Learning* en imagen médica para diagnóstico de Covid-19.

6

Como señalan Barberá, D. y Azagra, J. (2020), se evidencia un rápido aumento o *big-bang* de herramientas de *Deep Learning* para la detección de la enfermedad Covid-19, en donde “numerosos equipos de investigación han desarrollado algoritmos capaces de identificar la neumonía relacionada con Covid-19 con una precisión del 90 – 98% en pocos segundos” (2020 : 6).

En general, las iniciativas privadas y las alianzas interinstitucionales, comparten los mismos elementos metodológicos en el uso del *Deep Learning* y técnicas de redes neuronales convolucionales. Aunque difieren en la arquitectura de los modelos de *Deep Learning* aplicados, en todos los casos anuncian como resultado, la creación de herramientas con una alta confiabilidad para diagnóstico de Covid-19.

El trabajo de Yousefzadeh y otros (2020) presenta el desarrollo y validación de una herramienta basada en el aprendizaje profundo para el diagnóstico de Covid-19 en tomografías computarizadas (TC) de tórax. En función de los resultados obtenidos, los citados autores señalan una alta confiabilidad de dicha herramienta, la cual permite mejorar el rendimiento del diagnóstico de los expertos y ayudar especialmente en el diagnóstico de casos de Covid-19 no típicos o casos anormales No Covid-19 que manifiestan características de imagen de Covid-19 en la tomografía computarizada de tórax.

El Asnaoui y Chawki (2020) realizaron un estudio comparativo del uso de los modelos recientes de aprendizaje profundo (*VGG16*, *VGG19*, *DenseNet201*, *Inception_ResNet_V2*, *Inception_V3*, *Resnet50* y *MobileNet_V2*) para la detección y clasificación de la neumonía por coronavirus. Los resultados encontraron que el uso de *Inception_ResNet_V2* y *DenseNet201* proporciona mejores resultados en comparación con otros modelos utilizados en este trabajo (92,18% de precisión para *Inception-ResNetV2* y 88,09% precisión para *DenseNet201*). Los experimentos se realizaron

utilizando un conjunto de datos de rayos X y TC de tórax de 6087 imágenes (2780 imágenes de neumonía bacteriana, 1493 de coronavirus, 231 de Covid-19 y 1583 normal) y matrices de confusión para evaluar el rendimiento del modelo.

El trabajo de Civit-Masot y otros (2020) analizó la efectividad de un modelo de *Deep Learning* basado en VGG16 para la identificación de neumonía y Covid-19 mediante radiografías de tórax. Los resultados mostraron una alta sensibilidad en la identificación de Covid-19, alrededor del 100%, y con un alto grado de especificidad, lo que indica que se puede utilizar como prueba de cribado.

Se debe señalar que desde diferentes iniciativas y enfoques, varias organizaciones e instituciones en el mundo han publicado y compartido diversos conjuntos de datos alrededor de Covid-19, en algunos casos con acceso restringido y autorizado, y en otros de manera abierta. Dentro de los conjuntos de datos de imágenes de rayos X para fines de diagnóstico y como requisito para garantizar y validar el establecimiento de un sistema robusto, estos deben ser integrados a una buena estructura y forma de etiquetado, es decir, descriptivos, diagnósticos, prescriptivos y predictivos.

En tal sentido, el análisis de Barberá, D. y Azagra, J. (2020) señala diferentes aproximaciones de trabajo, con elementos diferenciados de organización y relaciones inter-institucionales, indicando que “Algunos de los algoritmos fueron desarrollados por informáticos en grupos independientes sin experiencia previa en imagen médica y sin rastro de colaboración con profesionales médicos (los denominados “covid cowboys” , Harvey, 2020)” (2020 ; 6).

De otra parte, los citados autores indican que otras herramientas de diagnóstico basadas en *Deep Learning*, han sido desarrolladas por empresas existentes y grupos de investigación especializados en el sector, en colaboración continua y estrecha con hospitales y otras instituciones. Allí, además de las bases de datos abiertas creadas con un enfoque colaborativo y solidario, dichas empresas están “utilizando bases de datos cerradas provenientes de consorcios de hospitales, que a su vez tendrán derecho a utilizar los algoritmos desarrollados por las empresas” (Barberá, D; Azagra, 2020 : 6).

7

Todo lo anterior representa, según sea el caso, la eliminación o la creación de barreras de entrada, alrededor de la I+D, el emprendimiento o el diseño de nuevos modelos de negocio. Es decir, en uno u otro caso, se evidencia que la aplicación de estrategias colaborativas o competitivas son determinadas en función de la interacción con el entorno externo.

2. Marco Metodológico

Desde una perspectiva general, el estudio ha sido abordado mediante la construcción de un marco teórico orientado a comprender la aplicación de la Inteligencia Artificial en imagen médica para el diagnóstico de Covid-19, como un estudio de caso de *Deep Learning* como invención de un método de invención.

Se ha aplicado un enfoque metodológico de tipo cualitativo, definido por Hernandez Sampieri et al., (2010, p. 364), como aquella investigación que se enfoca en comprender y profundizar los fenómenos, explorándolos desde la perspectiva de los participantes en un ambiente natural y en relación con el contexto. Conceptualmente, el proyecto ha tenido un alcance exploratorio, orientado a obtener información y aumentar el grado de conocimiento sobre la temática propuesta, con énfasis en el análisis del caso objeto de estudio.

En concordancia con los objetivos proyectados, el tipo de investigación es descriptiva - analítica, buscando identificar y especificar las características y diferentes elementos del fenómeno objeto de análisis: La invención de un método de invención, desde la perspectiva de la innovación.

A su vez, la fase descriptiva ha sido abordada mediante la combinación de dos perspectivas: la primera de carácter técnico y la segunda de tipo teórico. El alcance **técnico** ha estado basado en la aplicación de la metodología de **estudio de caso**, mediante la comparación de dos contextos o escenarios de innovación y aplicación de *Deep Learning* en imagen médica durante la crisis del Covid 19.

Tabla 1. Escenarios evaluados de innovación y aplicación de Deep Learning

Escenario	Escenario	Institución / Empresa	Fecha de la entrevista
E1	Empresa Consolidada Sector Informático	Entelai (Argentina)	02 – 07 - 2020
E2	Investigación Académica	Cooperación Interinstitucional (Diferentes Actores – Tabla 3)	-

Fuente: Elaboración propia

Para la recolección de información a partir de fuentes primarias, se aplicaron las metodologías cualitativas de entrevistas en profundidad. Para las fuentes secundarias, se revisaron publicaciones en periódicos, revistas, redes sociales, reportajes periodísticos y documentales.

Los resultados formulados a partir de la sistematización y análisis de la información, fueron obtenidos mediante aplicación del método de razonamiento inductivo, a partir del cual, se avanzó en la comprensión del caso de estudio.

Se debe señalar que el proceso de realización de las entrevistas fue particularmente complejo, debido a las dificultades para acceder a interlocutores de alto nivel y desarrolladores de *Deep Learning*, en una época de crisis determinada por el Covid-19, caracterizada por la dedicación de los grupos de investigación a sus trabajos y la poca disponibilidad para atender actividades al margen de sus agendas.

Si bien se contactaron nueve grupos de investigación o desarrolladores de *Deep Learning*, solamente uno de ellos accedió a desarrollar la entrevista, mientras que otro expresó directamente su negativa a participar. Adicionalmente, aunque se logró contactar a un grupo de investigación de una universidad en Colombia, tras el intercambio de varios emails, se evidenció la falta de disponibilidad e interés para participar en la entrevista. Además de las argumentaciones en torno al exceso de trabajo y la falta de tiempo para asignar a una entrevista, se presume cierto recelo alrededor del proyecto y un mayor interés en priorizar la atención de entrevistas de medios reconocidos de comunicación, que ofrecen una mayor visibilidad y difusión del trabajo investigativo, en comparación a entrevistas de corte académico, valoradas como una carga adicional en la agenda del investigador, al no ofrecer un reconocimiento social directo o una motivación personal.

Por lo expuesto, solamente fue posible realizar una entrevista, condición que a su vez determinó la necesidad de aplicar otra técnica de recolección de datos, basada en el análisis de contenidos de diferentes trabajos de investigación publicados sobre el área de estudio.

2.1. Técnicas de recolección de datos

Las técnicas de recolección de datos consideraron una combinación de entrevistas semi-estructuradas y análisis de contenidos.

2.1.1. Entrevistas semi-estructuradas

Para la realización del trabajo empírico se seleccionó la técnica de entrevista **semi-estructurada**, al ofrecer la mejor aproximación para abordar el fenómeno sobre el cual se pretende indagar, teniendo en cuenta la naturaleza del área objeto de estudio, los propósitos de investigación y las fuentes de información disponibles. Aunque inicialmente se pretendió realizar una entrevista para los dos escenarios de innovación identificados, las dificultades logísticas y disponibilidad de los entrevistados asociados al escenario académico, determinaron que dicho contexto fuera evaluado mediante uso de la técnica de análisis de contenidos en reemplazo de la entrevista.

Así mismo, se pretendía abordar el tema desde dos perspectivas diferentes, con el objetivo de garantizar una muestra más heterogénea y diversos enfoques sobre la aplicación del *Deep Learning* en la innovación, como un método de invención de la invención.

Tabla 2. Relación de expertos entrevistados

ID	Escenario	Organización / País	Nombre / Cargo	Fecha de la entrevista
E1	Empresa Consolidada Sector Informático	Entelai (Argentina)	CTO	02 – 07 - 2020

Fuente: Elaboración propia

9

2.1.2. Diseño de la entrevista

La revisión preliminar del marco teórico permitió identificar cuatro bloques de variables independientes, que modelan la aplicación y definen el impacto de la Inteligencia Artificial sobre la innovación y su caracterización como Invención de un Método de Invención:

- i) El contexto del proyecto y sus características de aplicación de la IA en imagen médica
- ii) Experiencias previas de los participantes del proyecto
- iii) Diferencias de las técnicas de IA con otras técnicas
- iv) Redes interinstitucionales y de cooperación.

Para cada pregunta temática se formularon las preguntas dinámicas (PD) encaminadas a dar respuesta a la pregunta temática, sin condicionar la respuesta del entrevistado y buscando evitar o inducir a sesgos o juicios reduccionistas. A partir de las consideraciones anteriores, se elaboró el guion de la entrevista semi-estructurada, de conformidad con las preguntas indicadas en el Anexo A.

2.1.3. Análisis de contenidos

De manera complementaria a las entrevistas semi-estructuradas señaladas, se realizó un análisis de contenidos de los trabajos de investigación identificados en la Tabla 3, los cuales fueron seleccionados en función de su utilidad frente al objetivo del presente estudio, al contener una descripción detallada de los métodos y características de las actividades desarrolladas.

Una categorización del perfil institucional y campos del conocimiento al cual pertenecen los autores de los trabajos referidos, indica que en todos los casos es

evidente el enfoque colaborativo entre organizaciones y entre autores; lo cual a su vez resalta la relevancia de las redes y relaciones entre instituciones y científicas. Es decir, a pesar del carácter intrínseco del *Deep Learning*, si bien ha irrumpido y modificado los mecanismos de interacción entre los investigadores, no ha reemplazado ni sustituido en modo alguno las relaciones, las cuales siguen siendo fundamentales para el desarrollo de los proyectos de investigación.

En tal sentido, llama la atención el gran número de instituciones y de autores participantes en cada trabajo mencionado. Así, para el caso del trabajo de Yousefzadeh et al., 2020, involucró a ocho instituciones y 16 investigadores entre *computer scientists* y radiólogos.

Tabla 3. Trabajos de investigación analizados

ID	Título / Proyecto	Institución	Fuente
P1	Sistema de aprendizaje profundo para la ayuda de diagnóstico Covid-19 Uso de imágenes pulmonares de rayos X	Universidad de Sevilla (España)	Civit-Masot y otros (2020)
P2	ai-corona: Radiologist-Assistant Deep Learning Framework for Covid-19 Diagnosis in Chest CT Scans	IPM, NRITLD Teherán – Irán	Yousefzadeh y otros (2020)
P3	Uso de imágenes de rayos X y aprendizaje profundo para detección automatizada de la enfermedad por coronavirus	Mohammed VI Polytechnic University (Marruecos) Moulay Ismail University (Marruecos)	El Asnaoui y Chawki (2020)
P4	Aplicación de aprendizaje profundo para la detección rápida de Covid-19 en rayos X usando nCOVnet	Jaypee University of Information Technology (India) Instituto Tecnológico de Monterrey (México)	Panwar y otros, (2020)
P5	Análisis de algoritmos de aprendizaje profundo en la base de datos de radiografías Covid-19	Krishna Institute Of Engineering And Technology (India)	Jaiswal y Singh, (2020)
P6	Diagnóstico de la neumonía Covid-19 a partir de imágenes de rayos X y TC mediante algoritmos de aprendizaje profundo y aprendizaje por transferencia	Koya University (Iraq) University of Wolverhampton (Reino Unido) King Saud University (Arabia Saudita)	Maghdid y otros., (2020)
P7	COVID-Net: un sistema neuronal convolucional profundo personalizado Diseño de red para la detección de casos Covid-19 a partir de imágenes de rayos X de tórax	University of Waterloo (Canadá)	Wang y Wong, (2020)
P8	Detección automatizada de casos de Covid-19 utilizando redes neuronales profundas con Imágenes de rayos x	Firat University, (Turquía) University of Bristol, (UK) Munzur University (Turquía) Ngee Ann Polytechnic, (Singapur) Asia University (Taiwan) Kumamoto University (Japón)	Barstugan y otros (2020)

Fuente: Elaboración propia

Sin embargo, de acuerdo con el contenido de la Tabla 4, se evidencia una tendencia predominante de trabajos colaborativos exclusivos de investigadores y desarrolladores de *Deep Learning*, en donde la participación de radiólogos es reducida o ausente; condición que a su vez refleja el estado actual y avance del *Deep Learning* en la investigación y diagnóstico a partir de imágenes médicas.

Tabla 4. Categorización de instituciones y autores participantes

ID	Fuente	Autores	Institución
P1	Civit-Masot y otros (2020)	Javier Civit-Masot Francisco Luna-Perejón Manuel Domínguez Morales Anton Civit	Departamento de Arquitectura y Tecnología Informática - Universidad de Sevilla.
P2	Yousefzadeh y otros (2020)	M. Yousefzadeh (1),(2),(3)*, P. Esfahanian (1), (2)*, S. M. S. Movahed (4),(3), S. Gorgin (1), (5), R. Lashgari (2), D. Rahmati6, (1), A. Kiani (7), S. Kahkouee (8), S. A. Nadji (9), S. Haseli (8), M. Hoseinyazdi (10), J. Roshandel (8), N. Bandegani (8), A. Danesh (8), M. Bakhshayesh Karam (8)†, A. Abedini (8)†	1 Escuela de Ciencias de la Computación, Instituto de Investigación en Ciencias Fundamentales (IPM), Teherán, Irán 2 Centro de Investigación en Ingeniería Cerebral, Instituto de Investigación en Ciencias Fundamentales (IPM), Teherán, Irán 3 Laboratorio multidisciplinario Ibn-Sina, Departamento de Física, Universidad Shahid Beheshti, Teherán, Irán 4 Departamento de Física, Universidad Shahid Beheshti, Teherán, Irán 5 Departamento de Ingeniería Eléctrica y Tecnología de la Información, Organización Iraní de Investigación para la Ciencia y la Tecnología (IROST), Teherán, Irán 6 Departamento de Ciencias de la Computación e Ingeniería, Universidad Shahid Beheshti, Teherán, Irán 7 Centro de Investigación de Enfermedades Traqueales, Instituto Nacional de Investigación de Tuberculosis y Enfermedades Pulmonares (NRITLD), Universidad de Ciencias Médicas y Servicios de Salud Shahid Beheshti, Teherán, Irán 8 Centro de Investigación de Enfermedades Respiratorias Crónicas, Instituto Nacional de Investigación de Tuberculosis y Enfermedades Pulmonares (NRITLD), Universidad Shahid Beheshti de Ciencias Médicas y Servicios de Salud, Teherán, Irán 9 Centro de Investigación de Virología, Instituto Nacional de Investigación de Tuberculosis y Enfermedades Pulmonares (NRITLD), Universidad de Ciencias Médicas y Servicios de Salud Shahid Beheshti, Teherán, Irán 10 Centro de Investigación de Imágenes Médicas, Departamento de Radiología, Universidad de Ciencias Médicas de Shiraz, Sira, Irán
P3	El Asnaoui y Chawki (2020)	Khalid El Asnaouia (1) Youness Chawk (2)	1_Ingeniería de Sistemas Complejos y Sistema Humano, Universidad Politécnica Mohammed VI, Benguerir, Marruecos; 2_Facultad de Ciencias y Técnicas, Universidad Moulay Ismail, Errachidia, Marruecos
P4	Panwar y otros, (2020)	Harsh Panwar (1) , P.K. Gupta (1) , Mohammad Khubeb Siddiqui (2) Ruben Morales-Menendez (2)	1_Departamento de Ingeniería y Ciencias de la Computación, Universidad de Tecnología de la Información de Jaypee, Wagnaghat, Solan, India

ID	Fuente	Autores	Institución
		Vaishnavi Singh (1)	2_ Escuela de Ingeniería y Ciencias, Tecnológico de Monterrey, Monterrey, NL, México
P5	Jaiswal y Singh, (2020)	Aman Jaiswal, Ankur Singh Bist	Krishna Institute Of Engineering And Technology (India)
			1_ Departamento de Ingeniería de Software- ing, Facultad de Ingeniería, Universidad de Koya, Región del Kurdistán-F.R.Iraq.
		Halgurd S. Maghdid (1)	2_ Oxford Drug Design, Oxford Centre for Innovation, Oxford
		Aras Asaad (2)	
P6	Maghdid y otros., (2020)	Kayhan Zrar Ghafoor (3)	3_ Departamento de Ingeniería de Software, Universidad Salahaddin-Erbil, Iraq; Escuela de Matemáticas e Informática, Universidad de Wolverhampton,
		Ali Safaa (4)	
		Muhammad Khurram Khan (5)	4_ Escuela de Matemáticas e Informática, Universidad de Wolverhampton,
			5_ Centro de Excelencia en Información mation Assurance, King Saud University, Riyadh, Arabia Saudita
P7	Wang y Wong, (2020)	Linda Wang 1,2,3, Zhong Qiu Lin 1,2,3, Alexander Wong 1,2,3	1_ Departamento de Ingeniería de Diseño de Sistemas, Universidad de Waterloo, Canadá 2_ Instituto de Inteligencia Artificial Waterloo, Canadá 3_ DarwinAI Corp., Canadá
P8	Barstugan y otros (2020)	Mucahid Barstugan (1), Umut Ozkaya (1), Saban Ozturk (2)	1_ Ingeniería eléctrica y electrónica, Universidad Técnica de Konya, Konya, Turquía 2_ Ingeniería eléctrica y electrónica, Universidad de Amasya, Amasya, Turquía

Fuente: Elaboración propia

2.1.4. *Procesamiento de información*

De acuerdo con las técnicas seleccionadas de recogida de datos y con el propósito de dar respuesta a la pregunta de investigación, la información recogida fue ordenada y analizada para presentar los resultados y elaborar las conclusiones correspondientes. Para ello, se realizó una aplicación combinada de dos técnicas cualitativas de análisis: Análisis de discurso y análisis de contenido.

El procesamiento de información se basó en la identificación y descripción detallada del contenido de la entrevista y los contenidos representativos de las fuentes secundarias analizadas, con el objetivo de realizar su codificación o sistematización, conceptualización e interpretación posterior.

De manera complementaria y de acuerdo a lo señalado por Dauster y Carter, (1960, p. 2) el análisis de contenido “se basa en la lectura (textual o visual) como instrumento de recogida de información, lectura que a diferencia de la lectura común debe realizarse siguiendo el método científico, es decir, debe ser, sistemática, objetiva, replicable, y válida. No obstante, lo característico del análisis de contenido y que le distingue de otras técnicas de investigación sociológica, es que se trata de una técnica que combina

intrínsecamente, y de ahí su complejidad, la observación y producción de los datos, y la interpretación o análisis de los datos”.

Conceptualmente, el desarrollo del procesamiento y análisis de información consideró los siguientes componentes y actividades comúnmente aplicadas en los métodos cualitativos de investigación (UOC, 2020), así:

- Extracción de datos relevantes
 1. Establecimiento de categorías a partir de la extracción de datos, en relación con las variables independientes y la pregunta de investigación.
 2. Separación de datos que no son relevantes, con el objeto de delimitar la información útil para el área objeto de estudio, con el propósito de afianzar los valores de originalidad de la propuesta, el interés científico, la viabilidad y pertinencia de la pregunta de investigación.
 3. Justificación de los métodos de análisis seleccionados, de acuerdo con la técnica de recogida de datos, la muestra empleada y los resultados.
- Creación de relaciones entre datos
 1. Creación de sistemas de relaciones entre los diferentes elementos, a partir de las categorías previamente identificadas. Por ejemplo, entre puntos de vista de entrevistados, entre contenidos narrativos de fuentes secundarias consultadas, etc.
 2. Identificación de diferencias y relaciones de convergencia para el análisis, la interpretación y análisis posterior.
- Interpretación y síntesis
 1. Interpretación de los datos en función de las relaciones creadas.
 2. Generación de una nueva codificación o conceptualización
- Interpretación y síntesis
 1. Remembranza e invocación de la pregunta inicial de investigación
 2. Identificación y definición de aquello que ha cambiado con relación al planteamiento inicial, tanto en cuanto a la técnica de recogida de datos como al método de análisis.
 3. Formulación de nuevas preguntas e identificación de las posibilidades futuras del trabajo de investigación.

13

3. Resultados y discusión

El creciente desarrollo del *Deep Learning* y su uso cada vez más extendido, señala una tendencia para convertirse en un nuevo estándar en cada área de aplicación, consolidándose como una Tecnología de Propósito de General (GPT). El análisis general de las innovaciones basadas en el uso del *Deep Learning* sobre diferentes aplicaciones de imágenes médicas, permite inferir que su uso es cada vez más generalizado y que está impulsando mayores innovaciones y transformaciones a una velocidad cada vez mayor.

Adicionalmente, se evidencia que el uso del *Deep Learning* en imagen médica para el diagnóstico de la Covid-19, incorpora un número significativo de los elementos y aspectos metodológicos y organizacionales identificados por Cockburn, Henderson y Stern (2018), para describir la Invención del Método de Invención (IMI) desde la perspectiva de aplicación del aprendizaje profundo.

3.1. Análisis de datos

3.1.1. *Deep Learning* y gestión del conocimiento

Los casos analizados de aplicación de la inteligencia artificial (IA) evidencian que el uso de *Deep Learning* representa la Invención de un Método de Invención para el diagnóstico predictivo de Covid-19 a partir de imágenes médicas. Al mismo tiempo, permiten establecer que la inteligencia artificial está cambiando de manera radical la forma de investigar, innovar y hacer I+D.

En comparación con las técnicas utilizadas hasta ahora para el desarrollo de software de diagnóstico de imágenes médicas, caracterizadas por la fuerte interacción entre médicos y desarrolladores informáticos, orientadas a convertir los atributos de la imagen, en elementos sistematizados y parametrizados para reflejar el estado de conocimiento alrededor del área de diagnóstico; el nuevo método basado en *Deep Learning*, está orientado a clasificar las imágenes y generar un diagnóstico directamente desde los datos, prescindiendo en gran medida, de la interacción entre expertos arriba mencionada.

Esto supone un cambio disruptivo en el proceso mismo de I+D, teniendo en cuenta que implica la eliminación y sustitución de procesos, operaciones, tareas y procedimientos que estaban basados anteriormente en el intercambio directo de conocimiento de las personas, y en la codificación de este a través de algoritmos y técnicas específicas de programación informática.

El nuevo método de invención requiere recursos y capacidades diferentes para su implantación y desarrollo. Lo anterior indica que la aplicación del *Deep Learning*, supone a su vez, un cambio en los recursos cognitivos necesarios para el desarrollo exitoso del proceso de I+D. Es decir, las áreas de dominio o del conocimiento, y en consecuencia los perfiles de las personas que lo poseen, incluyendo sus capacidades, habilidades, capacidades, aptitudes y actitudes, sus interacciones y los flujos de conocimiento, son y serán diferentes, en comparación con el método que se ha sustituido.

Todo lo anterior implica a su vez una reorganización en la dinámica, procesos y estrategias de gestión del conocimiento, alrededor de la IA como determinante del método de invención.

La invención de un método de invención desde la inteligencia artificial aplicada a imagen médica, no significa en modo alguno la creación espontánea, o de la nada, de nuevo conocimiento ni el desaprovechamiento del conocimiento anteriormente acumulado. Sin embargo, hacia el futuro, implicará un reacomodo de los modos de producción y obsolescencia, bien sea por desuso o falsación.

En la era de la tecnología, la potencia computacional y las aplicaciones efectivas comienzan con los datos. Los datos sirven como combustible impulsor en el campo de la inteligencia artificial y son el elemento fundamental en todas las perspectivas (Jaiswal y Singh, 2020 : 1269).

En este caso, si bien el *Deep Learning* elimina la participación directa del conocimiento médico explícito y codificado, requerido para atender tareas de parametrización o descripción de imágenes; se requiere aprovechar y acceder al conocimiento que es expresado a través del etiquetado de las imágenes. Así, la codificación del conocimiento se reduce al diagnóstico positivo o negativo de Covid en cada imagen médica. Lo anterior implica que el punto de partida del nuevo paradigma de invención sean las bases de datos con imágenes etiquetadas.

Como señalan Chanampe y otros (2019), la técnica de Redes Neuronales Convolucionales Profundas (DCNN) requiere una gran cantidad de datos de entrenamiento etiquetados, un aspecto crítico que puede ser un obstáculo difícil de sortear en el dominio de las imágenes médicas. Así mismo indican que es difícil alcanzar una alta precisión cuando no se posee una base de datos con gran número de ejemplos, aunque eventualmente se pueden emplear diferentes estrategias de entrenamiento para contrarrestar esta condición.

A pesar de las dificultades señaladas, que pueden afectar a diferentes campos del diagnóstico médico, para el caso de estudio se evidenció un entorno favorable de cooperación y acceso a bases de datos con imágenes médicas etiquetadas, como condición probablemente asociada a la movilización institucional, social y política alrededor de la pandemia.

3.1.2. *El Deep Learning en la transformación de la I+D*

Diferentes publicaciones han señalado que se puede hacer innovación sin hacer I+D, entre ellas el artículo escrito por Lee y Walsh (2016), publicado en *Research Policy*. Aunque los citados autores abordan lo que denominan innovación sin I+D desde el método tradicional de invención, el presente caso de estudio evidencia también que la inteligencia artificial en muchos escenarios, marca una tendencia acelerada y creciente de sustitución parcial o total de los procesos de I+D que preceden la innovación. Es decir, la innovación sin I+D es al mismo tiempo el resultado de la invención del método de invención.

Aunque la invención del método de invención supone ventajas en productividad, reducción de tiempo y reducción de costes, también implica riesgos y amenazas ocultas, algunas de ellas identificadas en el trabajo de Cockburn, Stern y Henderson (2018).

Según señala Simon (1997), citado por Lee y Walsh (2016), “la intuición, el juicio y la creatividad son básicamente expresiones de capacidades de reconocimiento y respuesta basadas en la experiencia y el conocimiento”. Por lo tanto, las ideas innovadoras se pueden desarrollar a partir del conocimiento generado a partir de oportunidades de aprendizaje en toda la empresa. En este caso, el aprendizaje generado y acumulado por la IA, puede aumentar las capacidades de experiencia y conocimiento para la innovación, en algunos casos fortaleciendo la I+D y en otros, limitándola o sustituyéndola.

Considerando que los procesos de innovación son el resultado de la combinación, intercambio y articulación del conocimiento adquirido a través de diferentes procesos de aprendizaje, así como la interacción y los mecanismos a través de los cuales se relacionan los miembros de una organización al interior de esta o con su entorno externo; el uso de herramientas basadas en *Deep Learning* representa en sí mismo la modificación del proceso de innovación aplicado al diagnóstico de Covid-19 mediante imágenes médicas. Al mismo tiempo refleja su potencial como herramienta de investigación a partir del uso de múltiples conjuntos de datos de dominio público, privado o una combinación de estos, para generar nuevas innovaciones desde diferentes aproximaciones.

Desde una aproximación conceptual, la IA como herramienta aplicada a la imagen médica ha incidido en la economía del proceso de investigación en términos de productividad, disminución de costos y reducción de tiempo. En este caso, el *Deep Learning*, además de ser el elemento fundamental incorporado al producto final, en este caso la herramienta para diagnóstico de Covid-19 mediante imagen médica, representa al mismo tiempo una nueva forma de crear nuevos productos y nuevos procesos de innovación.

3.1.3. *El Deep Learning en imagen médica como invención del método de invención*

El *Deep Learning* como invención del método de invención aplicado al presente caso de estudio, puede ser analizado desde las diferentes perspectivas consideradas en el trabajo de Cockburn, Henderson y Stern (2018), “*El impacto de la inteligencia artificial en la innovación*”, con incidencia sobre el método de investigación, las organizaciones, las instituciones y las políticas.

Utilización de datos sistematizados: El *Deep Learning* como herramienta incorpora un enfoque de investigación que adopta como punto de partida la utilización de grandes conjuntos de datos con una buena estructura y forma de etiquetado. Para el caso de imagen médica aplicada al diagnóstico de Covid-19 se evidencia que dichos datos, con una alta codificación implícita, contenida en imágenes, exigen una baja codificación explícita, contenida en el etiquetado (Covid-19 Positivo o Covid-19 Negativo), para ser aplicados en las fases de entrenamiento y validación de los modelos desarrollados en cada caso.

Fuentes de datos: Inicialmente, los datos utilizados son generados a partir de conocimiento previo, representado por imágenes médicas estructuradas en bases de datos privadas o repositorios para acceso y consulta abierta. A partir de allí y teniendo en cuenta que las herramientas son diseñadas para su implementación en la web, todo diagnóstico nuevo a partir de las imágenes utilizadas por los usuarios, permite generar nuevo conocimiento que a su vez ayuda a validar el modelo desarrollado y mejorar su precisión de diagnóstico.

Aunque existen otras fuentes de datos que pueden ser utilizadas en *Deep Learning*, entre ellas las transacciones en línea (p. ej., búsqueda o comportamiento de compra en línea) o los eventos físicos (p. ej., la salida de varios tipos de sensores o datos de geolocalización); se evidencia que los casos analizados de *Deep Learning* en imagen médica aplicada al diagnóstico de Covid-19 utilizan el conocimiento previo como única fuente de datos, representado como imágenes médicas etiquetadas. Se debe señalar que aunque los modelos son desarrollados para su uso en línea, la transacción o consulta en línea por parte de los usuarios, no constituye en sí misma una fuente de datos, salvo aquel conocimiento generado como resultado de co-relacionar la imagen médica y su diagnóstico. Si bien es posible incorporar herramientas métricas en las transacciones (p. ej. Número de descargas, número de consultas, número de imágenes utilizadas, diagnósticos positivos / negativos, etc.), y también incorporar datos de geolocalización (p. ej. País, ciudad, centro médico, etc.), para responder a preguntas o propósitos específicos, en principio, estos son de tipo marginal y no tienen una aplicación directa con el objetivo principal de la herramienta: Diagnosticar Covid-19 a partir de una imagen médica.

La Gestión y la organización de la innovación: Se evidenció que la organización para la innovación está basada principalmente en el *Know how* de la institución o del desarrollador individual, alrededor del *Deep Learning*. Aunque puede resultar importante el conocimiento del negocio o del área específica de trabajo (p.ej. Radiología, imágenes diagnósticas, etc.), la falta de experiencia no constituye una barrera o limitante para que una organización o desarrollador incursione en dicho campo.

Lo anterior se evidencia al revisar los casos de aplicaciones desarrolladas por estudiantes con gran dominio de habilidades de *Deep Learning* pero con una escasa aproximación o experiencia en el área biomédica o de diagnóstico. Es decir, la organización para la innovación desde el *Deep Learning* es principalmente un proceso de la gestión del conocimiento, a nivel individual y organizacional. Se debe destacar la importancia de las capacidades relacionadas con flexibilidad, adaptación y construcción

de relaciones interinstitucionales, como elementos esenciales para realizar una interacción e integración exitosa del *Deep Learning* con el área objeto de aplicación.

En tal sentido, el caso descrito por el entrevistado presenta la articulación y capacidades existentes al interior de una organización y cómo, desde la colaboración y un nuevo modelo interno de interacción, se genera una respuesta desde la innovación, para atender una problemática o reto específico:

“...Tenemos, somos alrededor de cinco programadores, si me contás a mí o no me contás ahí es un detalle, pero somos cinco trabajando en estos temas, y en general cada uno tiene sus líneas. Hay un chico que trabaja sobre las cosas de neuroradiología, neuroimágenes; otro que trabaja más sobre la parte de mamografía, otro que trabaja más en la parte de tórax. Y después hay un diálogo para tratar de poner en común las ideas de los nuevos modelos que van apareciendo y todo eso. Y de golpe apareció este proyecto, que lo que hicimos fue suspender la operatoria de [la empresa] durante una semana. Y dijimos, todos atacamos este problema. Y estuvimos más o menos una semana, diez días, metiéndole todos juntos a esto.” (Fernandez, D. Entrevista Julio 4 de 2020).

Desde una aproximación conceptual, el análisis presentado por Cockburn y otros (2018 : 22), señala que “Muchos tipos de I + D e innovación en general son efectivamente problemas de búsqueda intensiva en mano de obra con un alto costo marginal por búsqueda (Evenson y Kislev, 1975, entre otros)”.

Asimilando los procesos de I + D e innovación como un reto en la búsqueda de mano de obra calificada y especializada, es decir un proceso intensivo en la búsqueda de conocimiento experto, los citados autores anticipan el potencial del *Deep Learning* para reducir los costos marginales de dicha búsqueda, impulsando a las organizaciones de I+D a reemplazar mano de obra altamente calificada por inversiones de costo fijo en IA.

Los casos analizados de uso de *Deep Learning* en imagen médica para diagnóstico de Covid-19, evidencian la sustitución de una parte significativa del trabajo especializado, representado anteriormente por la fuerte interacción del conocimiento experto de médicos y radiólogos con expertos informáticos; hacia un conjunto de datos, imágenes, algoritmos, herramientas y capacidades informáticas y de procesamiento, las cuales constituyen inversiones en costo fijo, pero con una reducción importante del costo marginal de búsqueda de mano de obra calificada.

Con relación al cambio radical introducido por el *Deep Learning*, el entrevistado evidencia claramente dicha condición manifestando que:

“Eso sí cambió mucho. Antes era muy importante que el médico pudiera traducir su intuición y su experiencia mirando imágenes, a un algoritmo como una computadora podía entenderlo. Eso sí cambió. Eso ya hoy, es muy raro, no hace tanto falta. La traducción de la intuición, de la experiencia, a un algoritmo concreto tipo receta de cocina, eso es algo que hoy día no está haciendo falta. Justamente porque la inteligencia artificial ha avanzado tanto, que ahora eso, entre comillas, se arma sólo.

Entonces la experiencia del médico, ahora va más por el entendimiento del problema, por el manejo de la base de datos, la limpieza de la base de datos, y cómo usar un resultado de ese modelo, de forma que sea útil para el médico. Pero cuál es el algoritmo que el médico usó, para decir que esta es una lesión más grande o más chica, hoy no está

siendo tan importante, porque justamente eso es lo que resuelve la Inteligencia Artificial.

De hecho, tengo muchas discusiones con colegas que opinan que vamos a reemplazar a los médicos, y que no tendríamos que dialogar tanto, que los médicos usen las bases de datos, y nos las pasen hechas. Los radiólogos ya no necesitan traducirnos sus ideas a algoritmos. Eso ha llevado a todo básicamente”.

Sobresale aquí el hecho de que dicho capital, por su naturaleza, puede compartirse o alquilarse, y en consecuencia, “puede reducir las “barreras de entrada” en ciertos campos científicos o de investigación, en particular aquellos en los que los datos y algoritmos necesarios están disponibles libremente, al tiempo que se erigen nuevas barreras de entrada en otras áreas (p. ej. restringir el acceso a datos y algoritmos).” (Cockburn y otros., 2018 : 23)

Los casos de estudio analizados permiten inferir que en el futuro, como señalan dichos autores, se podrán crear mercados especializados para herramientas o servicios de investigación “capacitados” basados en *Deep Learning*, lo que empieza a suponer un cambio en el paradigma de la investigación y la innovación, y sobre todo, de las formas y estrategias de gestión de estas.

Aunque las diferentes iniciativas aquí estudiadas, impulsadas por instituciones, empresas privadas o emprendedores individuales, señalan que las aplicaciones han sido desarrolladas para ser consultadas en línea, de manera abierta y gratuita; se evidencia que las capacidades desarrolladas por los diferentes actores, alrededor del *Deep Learning*, así como la disponibilidad cada vez más generalizada de datos relevantes, pueden permitir su integración e incorporación a un mercado de servicios de IA compartidos.

18

Lo anterior se evidencia al tener en cuenta que los desarrolladores informáticos y científicos de datos vinculados a los proyectos analizados, al hacer uso de herramientas de *Deep Learning*, pueden incursionar en áreas médicas y de diagnóstico médico, aún sin ser expertos en dichas áreas, para generar o descifrar nuevo conocimiento codificado y especializado.

Sin embargo, más allá de los nuevos algoritmos, el proceso de invención y desarrollo de la innovación también involucra otros elementos, todo lo cual se evidencia cuando el entrevistado destaca los beneficios y desventajas de los nuevos desarrollos basados en *Deep Learning*:

“Hay una cosa buena y una cosa mala. Deep Learning funciona, las técnicas viejas no funcionaban tan bien, de eso no hay duda. Si vos mirás el rendimiento de estos modelos, andan muchísimo mejor que lo que funcionaba antes. Eso efectivamente lo hacen, el problema es que el mundo real no funciona así. Cualquier modelo de estos, de cualquiera de estos niños genios que hacen Deep Learning, lo ponés en un hospital real, lo ponés en manos de un médico y no funciona. Y no digo que no funciona porque andan mal los modelos. Los modelos andan bien probablemente, pero no es sólo cuestión de modelos el hacer un diagnóstico médico”

Así mismo, es evidente que el *Deep Learning* puede inducir, en cierta forma, a una desconexión con el área de conocimiento que se pretende investigar. Es decir, escenarios en dónde se aplica conocimiento avanzado, bajo contextos que omiten la comprensión de los procesos y fenómenos estudiados. Lo anterior es evidenciado por el entrevistado al señalar que:

“Pero por otro lado, los modelos anteriores eran basados en conocimiento de expertos y entonces uno tenía exactamente el conocimiento de lo que estaba haciendo. Estoy detectando bordes, estoy detectando contrastes, estoy detectando figuras o efectos de las lesiones, y cosas por el estilo. Y ahora, eso se perdió..... Yo creo que ese es el principal error de esta tendencia que hay de, analizo los datos, pero no me cuentas nada, no me interesa saber que hay detrás, yo te hago el modelo. Para mí, no funciona así”.

Aunque el *Deep Learning* puede generar “una caja negra de conocimiento” que no permite, en principio, una comprensión o explicación de los fenómenos que la subyacen, sí es lo suficientemente efectiva y útil para dar respuesta a procesos que deben estar soportados en predicciones o toma de decisiones. Probablemente en un futuro cercano, como se evidencia con el desarrollo y aplicación cada vez más extendida de herramientas de *Transform Learning* y *Deep Feature Synthesis*, se podrá generar nuevo conocimiento, estructurado, accesible y con una codificación explícita, ya no contenido como una “caja negra” sino expresado como un “texto académico”. Es decir, que el *Deep Learning* permitirá conocer cuál fue el atributo o fenómeno identificado o aprendido, permitiendo a su vez la generación de nuevo conocimiento explícito y codificado, disponible y accesible.

Para el entrevistado, lo anterior supone la creación de conocimiento generado directamente desde la inteligencia artificial, con implicaciones profundas no solo en la ampliación de la frontera del conocimiento sino en nuevos retos alrededor de la propiedad intelectual de dicho conocimiento.

19

“Entonces yo creo que estamos, y la comunidad de *Deep Learning* lo está haciendo, esta no es una idea mía sino que se está tratando de salir de este mundo vertiginoso de redes cada vez más grandes y cada vez más complejas, a un mundo dónde sean redes que podamos entender...Entonces que podamos hacer la marcha atrás, entrenamos una red para que se aprenda estos atributos, y ahora le podamos preguntar a la red, cuál fue el atributo que aprendiste que permitió hacer lo que hacés tan bien. Esa parte de interpretabilidad de redes neuronales, creo que es el futuro, y creo que tiene una doble función. Por un lado, estar seguros que la red está andando bien porque hizo las cosas bien, y por el otro lado aprender. Imaginate si yo pudiera decirle a un médico, lo que tenés que mirar para detectar covid es si la tonalidad del pulmón izquierdo es distinta de la tonalidad del pulmón derecho, no sé. En nuevas enfermedades, donde todavía no se sabe qué es lo que distingue de otras cosas, en una de una de esas cosas, estas redes aprendiendo, si fueran fácilmente interpretables podríamos usarlas para aprender”.

Todo lo anterior, coincide con lo resaltado por Cockburn y otros (2018 : 24), al señalar que “la democratización de la innovación también [puede ir] acompañada de una falta de inversión por parte de investigadores individuales en habilidades de investigación especializadas y experiencia especializada en cualquier área dada, reduciendo el nivel de profundidad teórica o técnica en la fuerza laboral”.

Dicho fenómeno a su vez puede ocasionar fuertes modificaciones en las dinámicas de las trayectorias orientadas al desarrollo de las carreras de investigación, siendo reemplazadas por el desarrollo de capacidades enfocadas en la generación de nuevos hallazgos basados en *Deep Learning*.

Es decir, el éxito del *Deep Learning*, puede no solo desestimular a largo plazo las carreras de investigación innovadoras realizadas por personas que están en la frontera

de investigación; sino que puede reemplazar la mano de obra técnica calificada en el sector de la investigación, realizando su sustitución por Inteligencia Artificial, interrumpiendo los mercados laborales apoyados en períodos largos de la capacitación y educación requeridas para formar personal científico y técnico.

La transformación de la interacción del conocimiento experto: Si bien se evidencia la disrupción del *Deep Learning* como una herramienta que está modificando los procesos de investigación y generación de conocimiento, el caso analizado de imagen médica evidencia que aunque se evidencian cambios sustanciales en la interacción del conocimiento experto, la posibilidad de prescindir del conocimiento humano experto o la interacción humana, parece todavía lejana y requerirá varias décadas más para su desarrollo.

Sin embargo, el *Deep Learning* y la generación de conocimiento a partir de herramientas de *Transform Learning*, suponen nuevas cuestiones alrededor del método de invención y el sistema de patentes desde una perspectiva técnica y legal.

Democratización de la I+D: Además del impacto de la IA sobre los métodos de investigación y de invención, la IA tiene el potencial de modificar todos los elementos que forman parte de la cadena de la I+D.

En principio, la IA permite impulsar la democratización de los procesos de investigación e invención, al reducir las barreras de entrada, disminuir los costos y permitir la incursión de nuevos y múltiples actores en diferentes áreas del conocimiento.

Son numerosos y crecientes los casos y aplicaciones desarrolladas por estudiantes o emprendedores que emprenden proyectos individuales, con pocos recursos, para desarrollar algoritmos y modelos específicos con el propósito de atender problemas o necesidades particulares del mercado.

20

Aunque desde la perspectiva de la aplicación de la IA como invención del método de invención se podría inferir una mayor probabilidad de éxito para cualquier iniciativa o proyecto basado en la formulación de modelos y algoritmos precisos y funcionales; en la realidad, la posibilidad de llevarlos al mercado o a la práctica, sigue dependiendo de diferentes factores y barreras. Si bien un modelo muy preciso para diagnóstico de Covid19 en imagen médica puede ser formulado en muy corto tiempo, su validación final y certificación a través de estudios clínicos es un proceso complejo, costoso y demorado, condición que actúa como barrera de entrada para muchos actores.

Si bien la IA ha permitido la creación de emprendimientos que en corto tiempo son valorizados en cifras de varios millones de dólares, dicha condición es la excepción y no corresponde a la regla general. Lejos del imaginario exitoso de *startups* que pretenden alcanzar el ideal de *Silicon Valley*, las aplicaciones de la IA no reducirán el riesgo al fracaso que enfrenta cualquier emprendimiento.

Considerando que la aplicación de la IA confiere fuertes ventajas competitivas a cualquier empresa, su uso e incorporación generalizada por parte de otros competidores del sector, hace que a mediano y largo plazo tienda a convertirse en un estándar de la industria, dejando de ser un elemento propiamente diferenciador, todo lo cual probablemente intensificará la competencia y acelerará el desarrollo de la invención del método de la invención.

Las zonas grises del marco regulatorio y el *Deep Learning*: Aunque desde hace varias décadas se viene haciendo un uso cada vez creciente de los datos, el *Deep Learning* impulsará aún más el uso de estos y su valorización, trayendo consigo nuevos

retos y consideraciones éticas alrededor de la protección de datos, la seguridad, el anonimato, la privacidad, la trazabilidad, generación de valor, etc., como aspectos convergentes y en muchos casos antagónicos.

Teniendo en cuenta que el desarrollo de la IA y las aplicaciones basadas en *Deep Learning* ha sido más rápido que el desarrollo de los marcos normativos y regulatorios aplicables a las nuevas cuestiones, se evidencia el surgimiento nuevos retos y conflictos alrededor de elementos sensibles como la anonimidad el control de datos o la redistribución de responsabilidades.

La conflictividad ética y legal derivada de los vacíos y zonas grises de la legislación frente a las aplicaciones de la IA, determina que en muchos casos, empresas grandes y consolidadas eviten incursionar en ciertas áreas de trabajo, con el fin de prevenir los riesgos asociados a costosas demandas. Así mismo, determina que otras empresas, tengan una percepción diferente de la exposición al riesgo y decidan aprovechar las zonas grises a partir de la combinación de su modelo de negocio, sus ventajas competitivas, su conocimiento del sector y su afinidad o aversión al riesgo desde una valoración costo – beneficio.

La anonimidad, el control de los datos o la distribución de responsabilidades aplicados a imagen médica para diagnóstico de Covid-19, aún son elementos que deben ser desarrollados para garantizar la implementación masiva de las herramientas.

Resolver cómo se debe garantizar la anonimidad de las personas y sus datos, manteniendo una trazabilidad de los mismos, presenta múltiples escenarios definidos por el balance entre dichos elementos. Así mismo, la posibilidad de que cualquier persona autorice el uso de sus datos y posteriormente decida suspender la autorización de uso, aunque en principio puede ser un tema operativo y simple, en la práctica puede ser un proceso con un alcance de mayor complejidad.

21

Aspectos como quién debe realizar y cómo debe ser realizado el control de los datos, en contextos caracterizados por la interacción de múltiples actores como hospitales, personal médico, usuarios finales de las herramientas, empresas desarrolladoras de las herramientas de IA, etc., también presenta límites difusos, no solo alrededor de los datos crudos, sino alrededor de los datos procesados y el conocimiento generado a partir de estos.

Lo anterior evidencia lo señalado por Cockburn y otros (2018) frente a la posibilidad de que las empresas pueden consolidar una ventaja en una etapa temprana, con el propósito de posicionarse para poder generar más datos y construir a partir del *Deep Learning*, una barrera de entrada para otros competidores, garantizando su dominio del mercado al menos a mediano plazo.

Otro elemento en consideración se relaciona con el contexto de uso de los datos para propósitos académicos y de investigación médica, en donde las personas por empatía o por interés colaborativo autorizan fácilmente el uso de dichos datos. Sin embargo, el aprovechamiento posterior de los desarrollos académicos e investigaciones para apalancar usos comerciales e incluso nuevas oportunidades y aplicaciones imprevistas, supone una transición que no está exenta de conflictos éticos o legales.

La posibilidad de hacer que los datos anonimizados de las personas sean de dominio público, para que las empresas puedan emplearlos en sus procesos de innovación, supone al mismo tiempo la discusión alrededor de los derechos de propiedad intelectual y sus implicaciones sobre el sistema de patentes.

La redistribución de responsabilidades también constituye una tarea pendiente. Si bien las herramientas son empleadas para apoyar al personal médico en las decisiones que deben tomar para diagnosticar Covid-19, se hace evidente la necesidad de definir los límites de responsabilidades asociadas a la toma de decisiones y diagnóstico de la enfermedad. Aunque los algoritmos basados en IA han sido puestos al alcance de las instituciones de salud y la comunidad médica, mediante aplicaciones gratuitas disponibles en línea, con un enfoque experimental pero con un alto nivel de precisión; en donde los desarrolladores advierten que su uso como herramienta de apoyo es de carácter discrecional por parte del médico o radiólogo y en consecuencia, se abstienen de asumir cualquier responsabilidad sobre su uso. No obstante, la futura incorporación de los algoritmos para diagnóstico y su aplicación generalizada en la práctica médica requerirá la construcción de un marco normativo que permita definir y diferenciar en cada caso, las responsabilidades compartidas y diferenciadas entre médicos, desarrolladores de las herramientas de IA y las organizaciones detrás de estos, incluyendo aquellos requisitos de certificación que deben cumplir los desarrolladores para validar las herramientas.

Desde la perspectiva del entrevistado, la definición de responsabilidades es un factor que debe ser resuelto para que las aplicaciones de IA y el diagnóstico directo sistematizado tengan una mayor aplicación:

“Eso es algo que está en plena discusión. Quién se hace responsable del diagnóstico. Y yo creo que a la larga va a ser una responsabilidad compartida. Por ejemplo, supóngase un médico que hace una primera lectura rápida, en algún momento, y que después pide una segunda opinión a un algoritmo. O al revés, se hace primero una opinión con un algoritmo y si el algoritmo no está seguro, se hace una segunda opinión con un médico. O que todas las imágenes pasen por dos sistemas, uno automatizado y uno de humano. Entonces ahí, pensar que el algoritmo no tiene responsabilidad, está mal. Si está devolviendo un diagnóstico, tiene que poder, tener su responsabilidad, igual que lo tiene un médico”.

22

3.1.4. *El Deep Learning y los nuevos métodos*

La aplicación de *Deep Learning* representa una nueva metodología de aproximación a la investigación y al proceso mismo de innovación. En tal sentido, el análisis de contenidos de las fuentes señaladas en la Tabla 3, permite establecer elementos comunes relacionados con los aspectos metodológicos de investigación e invención empleados para la construcción de las diferentes herramientas o proyectos formulados para diagnóstico de Covid-19.

En todos los casos, el punto de partida para la aplicación y desarrollo de la inteligencia artificial son los datos sistematizados. “... se necesitan datos en una buena estructura y forma de etiquetado, es decir, descriptivos, diagnósticos, prescriptivos y predictivos, lo que puede probar el establecimiento de un sistema robusto” (Jaiswal y Singh, 2020, p. 1269).

Todos los proyectos analizados pretenden como objetivo principal, construir una metodología de diagnóstico automático. En todos ellos, se evidencia la aplicación de la técnica de Redes Neuronales Convolucionales Profundas (DCNN), como técnica de uso generalizado para el diagnóstico a partir de imagen médica en los casos analizados.

Una revisión de los métodos empleados en los trabajos de aplicación de *Deep Learning* en imagen médica para diagnóstico de Covid-19, indican que:

“Todos ellos requieren un conjunto de datos compuesto por varias imágenes correspondientes a pacientes enfermos y sanos (todos ellos previamente etiquetados por un profesional). Con este conocimiento, los sistemas basados en redes neuronales pueden analizar automáticamente esas imágenes y extraer las características necesarias para diagnosticar la enfermedad. Estos sistemas requieren varios pasos como una etapa de pre-procesamiento, la correcta elección de la arquitectura de red, una etapa de entrenamiento (que en ocasiones requiere supervisión), entre otros. En los sistemas de *Deep Learning*, aunque el modelo de red ya está establecido, es muy común utilizar un paso de pre-procesamiento para adaptar las entradas a las que necesita ese modelo”. (Civit-Masot y otros, 2020 : 3)

El artículo de Sisamón y Vidarte (2020) describe, además del uso de bases de datos que contienen imágenes de radiografía Covid-19, el proceso que debe seguirse para seleccionar y aplicar la mejor arquitectura de redes neuronales convolucionales, entre ellas: VGG16, Xception, ResNet-50, ResNet-101, DesNet-201 e InceptionResNetV2. Para dicho caso, los mejores resultados se obtuvieron utilizando Xception Net con un valor de precisión del 97,34% durante la evaluación de la prueba

El trabajo desarrollado por Yousefzadeh y otros (2020), permitió diseñar una herramienta para apoyar el trabajo de los radiólogos en el diagnóstico de Covid-19 con tomografías computarizadas (TC) de tórax. Dicha herramienta está conformada por dos bloques principales: Un extractor de características basado en DCNN y un clasificador con una agrupación promedio y capa completamente conectada para clasificar una TC tomando como referencia tres categorías o resultados posibles: Covid-19 Anormal, No Covid-19 Anormal y Normal.

23

En este caso, el conjunto de entrenamiento (*training set*) fue definido utilizando los informes de dos radiólogos experimentados. El conjunto de validación de clases anormales de Covid-19 se definió utilizando el consenso general de un conjunto de criterios que indican infección por Covid-19. Además, los conjuntos de validación para las clases normales y no anormales de Covid-19 fueron definidos por un radiólogo experimentado diferente. Es decir, la participación e intensidad del conocimiento experto es aplicado para temas específicos de etiquetado de imágenes y validación del desempeño de la herramienta creada.

3.2. Conclusiones y reflexiones finales

A partir del caso de estudio analizado se evidencia que el *Deep Learning* como herramienta disruptiva está cambiando los métodos de investigación e invención, con un alto impacto en la productividad, reducción de costes y disminución de tiempo.

Desde la perspectiva del concepto de la “*invención del método de invención*” analizado por Cockburn, Henderson y Stern, 2018, se observa la sustitución de operaciones y actividades basadas en la interacción intensiva de conocimiento entre científicos, ingenieros y técnicos por operaciones basadas en capacidades informáticas de procesamiento de datos, en este caso, mediante aplicación de herramientas de *Deep Learning*.

En comparación con las técnicas anteriormente aplicadas para el desarrollo de software de diagnóstico de imágenes médicas, caracterizadas por la fuerte interacción entre médicos y desarrolladores informáticos, orientadas a convertir los atributos de la imagen, en elementos sistematizados y parametrizados para reflejar el estado de conocimiento alrededor del área de diagnóstico; el nuevo método basado en *Deep Learning*, está orientado a clasificar las imágenes y generar un diagnóstico directamente

desde los datos mismos, prescindiendo en gran medida, de la interacción referida entre expertos.

El uso del *Deep Learning* supone un cambio radical en la gestión del conocimiento, lo cual a su vez implica modificaciones significativas en los procesos de gestión del capital humano, el capital estructural (estrategia, diseño organizativo, protocolos, uso de TICs) y el capital relacional, en donde el balance final resultante de la interacción entre tales procesos, definirá la futura dinámica, evolución e invención del método de invención.

Lo anterior es particularmente relevante si se tiene en cuenta que el *Deep Learning* y las otras técnicas de la IA, permitirán generar mayor conocimiento, a una velocidad mayor y que cuanto más conocimiento disponible exista, se presentarán más opciones de generar nuevo conocimiento.

Frente a la necesidad y relevancia de la disponibilidad de datos etiquetados, que pueden afectar a diferentes campos del diagnóstico médico, en el caso de estudio se evidenció un entorno favorable de cooperación y acceso a bases de datos con imágenes médicas etiquetadas, como condición probablemente asociada a la movilización institucional, social y política alrededor de la pandemia.

Aunque el nuevo método de invención desde el *Deep Learning* no existe aún como un paradigma dominante de los procesos actuales de investigación e innovación, se infiere que el uso creciente de la IA permitirá en el futuro la generación de conocimiento autónomo e invenciones autónomas. Lo anterior implicará también una redefinición de los roles, funciones y operaciones que debe realizar el investigador o inventor, así como sus habilidades y áreas de formación, teniendo en cuenta que la generación de nuevo conocimiento en áreas de frontera de la investigación seguirá dependiendo del criterio, interacción y dirección humana.

24

Probablemente se seguirá avanzando hacia escenarios de automatización de algunos procesos de investigación, pero difícilmente se logrará, en un horizonte de corto y mediano plazo, una automatización total de la investigación que elimine totalmente la participación humana. De hecho, un escenario imaginario de construcción de ciencia con una participación humana reducida o sin la participación de esta, basada únicamente en la inteligencia artificial, daría lugar a un estado de autarquía y endogamia científica en desmedro de la ampliación de las fronteras del conocimiento, diversidad o pertinencia.

Se observa que el uso de *Deep Learning* permite en principio una democratización de la I+D, al permitir la incursión de nuevos actores, como consecuencia de la reducción de costes de investigación, la disponibilidad abierta de conjuntos de datos y la disminución o desaparición de otras barreras de entrada. Lo anterior ha permitido que estudiantes, investigadores o emprendedores independientes hayan desarrollado en muy corto tiempo, herramientas para diagnóstico de Covid-19 mediante uso de *Deep Learning* en imagen médica.

Sin embargo, siguen y seguirán persistiendo otras barreras asociadas a los marcos regulatorios y los necesarios procesos de validación y certificación, todo lo cual determina que un algoritmo de alta precisión no es suficiente para garantizar su uso masivo o adopción por parte de los usuarios o del mercado.

A partir de lo expuesto, se identifican diferentes líneas de investigación que deben seguir siendo abordadas en el futuro desde una perspectiva social, con el fin de estudiar el fenómeno de la disrupción de la IA y su impacto, considerando áreas como: Factores que potencian el desarrollo y uso generalizado, barreras que dificultan su utilización,

efectos sobre la productividad de los procesos de I+D, patentes y publicaciones científicas, democratización de la investigación y acceso de nuevos actores autónomos, articulación con políticas de fomento de la ciencia, la tecnología y la innovación (CTel), adopción por parte de los sistemas de CTel e incluso el desarrollo de técnicas de IA y *Deep Learning* para el estudio de la ciencia, la tecnología y la innovación en el área de la IA y el *Deep Learning*.

En función del uso creciente del *Deep Learning*, otras líneas de investigación pueden estar asociadas a conceptos como la “automatización de la automatización”, la “investigación autónoma” o incluso otros conceptos como la posibilidad de “hacer innovación sin I+D”.

Además de seguir avanzando en la problematización de los temas anteriores, se evidencia que han cobrado una gran relevancia y pertinencia los estudios orientados a comprender y resolver temas sensibles como el control de datos, la anonimidad, la responsabilidad, las patentes generadas por la aplicación de la IA o el conocimiento autónomo, todos ellos, elementos esenciales para el desarrollo de marcos regulatorios y normativos que den respuesta a los nuevos retos y que aporten elementos para el debate ético y político.

Bibliografía

- BARBERÁ, DAVID; AZAGRA, J. (2020). *Deep learning and control transitions in collaborative digital innovation in medical image: An invention of the method of invention or just another research tool? - Documento de trabajo sin publicar.*
- BARSTUGAN, M., OZKAYA, U., & OZTURK, S. (2020). *Coronavirus (COVID-19) Classification using CT Images by Machine Learning Methods.* 5, 1–10. <http://arxiv.org/abs/2003.09424>
- CHANAMPE, H., ACIAR, S., VEGA, M. DE LA, MOLINARI SOTOMAYOR, J. L., CARRASCOSA, G., & LOREFICE, A. (2019). Modelo de redes neuronales convolucionales profundas para la clasificación de lesiones en ecografías mamarias. *XXI Workshop de Investigadores En Ciencias de La Computación (WICC 2019, Universidad Nacional de San Juan).*, Cidi. <http://sedici.unlp.edu.ar/handle/10915/77381>
- CIVIT-MASOT, J., LUNA-PEREJÓN, F., MORALES, M. D., & CIVIT, A. (2020). Deep learning system for COVID-19 diagnosis aid using X-ray pulmonary images. *Applied Sciences (Switzerland)*, 10(13). <https://doi.org/10.3390/app10134640>
- COCKBURN, I., HENDERSON, R., & STERN, S. (2018). *The Impact of Artificial Intelligence on Innovation.* <https://doi.org/10.3386/w24449>
- DAUSTER, F., & CARTER, B. G. (1960). Las revistas literarias de Hispanoamerica. Breve historia y contenido. *Hispania*, 43(2), 296. <https://doi.org/10.2307/334486>
- EL ASNAOUI, K., & CHAWKI, Y. (2020). Using X-ray images and deep learning for automated detection of coronavirus disease. *Journal of Biomolecular Structure and Dynamics*, 0(0), 1–12. <https://doi.org/10.1080/07391102.2020.1767212>

- FERNANDEZ, D. (2020). *Entrevista. Diego Fernández. Experto en IA aplicada a imagen médica*.
<https://www.ciencia.gob.es/portal/site/MICINN/menuitem.26172fcf4eb029fa6ec7da6901432ea0/?vgnnextoid=70fcdb77ec929610VgnVCM1000001d04140aRCRD>
- GONZÁLEZ, B. (2020). *El virus de la COVID-19 afecta a las publicaciones científicas*.
https://www.uoc.edu/portal/es/news/actualitat/2020/320-covid-afecta-publicaciones-cientificas-calidad.html#.Xx_dytnVbPU.twitter
- HERNANDEZ SAMPIERI, R., FERNANDEZ COLLADO, C., & BAPTISTA LUCIO, M. DEL P. (2010). Metodología de la investigación. In *Metodología de la investigación*.
<http://www.casadellibro.com/libro-metodologia-de-la-investigacion-5-ed-incluye-cd-rom/9786071502919/1960006>
- JAISWAL, AMAN, SINGH, A. (2020). Analysis of Deep Learning algorithms on COVID-19 Radiography Database. *International Journal of Advanced Science and Technology*, June. <https://doi.org/10.13140/RG.2.2.27462.91203>
- KIM, D. (2020). 'AI-Generated Inventions': Time to Get the Record Straight? *GRUR International*, 69(5), 443–456. <https://doi.org/10.1093/grurint/ikaa061>
- LECUN, Y., BENGIO, Y., & HINTON, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- LEE, Y. N., & WALSH, J. P. (2016). Inventing while you work: Knowledge, non-R&D learning and innovation. *Research Policy*, 45(1), 345–359. <https://doi.org/10.1016/j.respol.2015.09.009>
- MAGHDID, H. S., ASAAD, A. T., GHAFOR, K. Z., SADIQ, A. S., & KHAN, M. K. (2020). *Diagnosing COVID-19 Pneumonia from X-Ray and CT Images using Deep Learning and Transfer Learning Algorithms*. 1–8. <http://arxiv.org/abs/2004.00038>
- NAHID, A. AL, SIKDER, N., BAIRAGI, A. K., RAZZAQUE, M. A., MASUD, M., KOUZANI, A. Z., & MAHMUD, M. A. P. (2020). A novel method to identify pneumonia through analyzing chest radiographs employing a multichannel convolutional neural network. *Sensors (Switzerland)*, 20(12), 1–18. <https://doi.org/10.3390/s20123482>
- PANWAR, H., GUPTA, P. K., SIDDIQUI, M. K., MORALES-MENENDEZ, R., & SINGH, V. (2020). Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals*, 138, 109944. <https://doi.org/10.1016/j.chaos.2020.109944>
- ROTMAN, D. (2019). *AI is reinventing the way we invent | MIT Technology Review*. <https://www.technologyreview.com/2019/02/15/137023/ai-is-reinventing-the-way-we-invent/>
- SISAMÓN, F. L., & VIDARTE, R. L. (2020). *Analysis of Deep Learning Models for COVID-19 Diagnosis from X-Ray Chest Images*. June, 1–6. <https://doi.org/10.13140/RG.2.2.16482.35520>

- UOC, U. O. de C. (2020). *Material Docente PEC 3 : El análisis de los datos Descripción y enunciado Pasos a seguir , formato de entrega y materiales orientadores* (pp. 1–3). Universitat Oberta de Catalunya.
- WANG, L., & WONG, A. (2020). *COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images*. 1–12. <http://arxiv.org/abs/2003.09871>
- YOUSEFZADEH, M., ESFAHANIAN, P., MOVAHED, S. M. S., GORGIN, S., LASHGARI, R., RAHMATI, D., KIANI, A., KAHKOUEE, S., NADJI, S. A., HASELI, S., HOSEINYAZDI, M., ROSHANDEL, J., BANDEGANI, N., DANESH, A., KARAM, M. B., & ABEDINI, A. (2020). *ai-corona: Radiologist-Assistant Deep Learning Framework for COVID-19 Diagnosis in Chest CT Scans*. 1–14. <https://doi.org/10.1101/2020.05.04.20082081>