

**Inteligencia artificial aplicada al diagnóstico radiológico de la enfermedad pulmonar  
obstructiva crónica: una revisión documental**

Gregoria Lucia caballero Ortiz

Asesor

Edna Rocio Jamaica Guio

Universidad Nacional Abierta a Distancia - UNAD

Escuela de Ciencias de la Salud - ECISA

Tecnología en Radiología e Imágenes Diagnosticas.

2026

## Resumen

La enfermedad pulmonar obstructiva crónica (EPOC) representa uno de los mayores problemas de salud pública mundial, con prevalencia estimada de 480 millones de personas y mortalidad de 3,5 millones de defunciones anuales. A pesar de esta magnitud, la EPOC permanece subdiagnosticada por las limitaciones de la espirometría como método de detección y la baja sensibilidad de la radiografía de tórax en estadios tempranos. En este contexto, la inteligencia artificial (IA), especialmente los modelos de aprendizaje profundo basados en redes neuronales convolucionales, surge como herramienta prometedora para mejorar la detección y estadificación de la EPOC a partir de imágenes radiológicas. El objetivo es analizar la evidencia científica sobre el uso de algoritmos de IA para el diagnóstico radiológico de la EPOC, identificando alcances, limitaciones y proyecciones clínicas. La metodología corresponde a un diseño cualitativo documental de enfoque descriptivo-analítico, mediante revisión de literatura publicada entre 2016 y 2026 en PubMed, SciELO, ScienceDirect y Cochrane, con términos MeSH en español e inglés. Los resultados indican que modelos como ResNet, DenseNet y EfficientNet, entrenados sobre ChestX-ray14 y MIMIC-CXR, alcanzan valores de AUC superiores a 0,85 en la clasificación de la EPOC. Persisten desafíos de opacidad de los modelos, generalización poblacional y consideraciones éticas para su implementación clínica. Se concluye que la IA representa un complemento diagnóstico valioso en radiología de tórax, siempre que su uso se acompañe de marcos regulatorios claros y de la participación del tecnólogo en radiología como auditor tecnológico.

**Palabras Clave:** EPOC, inteligencia artificial, radiografía de tórax, aprendizaje profundo, diagnóstico radiológico.

## Abstract

Chronic obstructive pulmonary disease (COPD) is one of the leading public health problems worldwide, with an estimated prevalence exceeding 480 million people and a mortality of approximately 3.5 million deaths annually. Despite its epidemiological magnitude, COPD remains widely underdiagnosed, partly due to the limitations of spirometry as the sole detection method and the low sensitivity of conventional chest radiography for identifying early stages. In this context, artificial intelligence (AI), and particularly deep learning models based on convolutional neural networks, emerges as a promising tool to improve COPD detection and staging from radiological images. The present work aims to analyze the available scientific evidence on the use of artificial intelligence algorithms for the radiological diagnosis of COPD, identifying their scope, limitations, and clinical projections. The methodology corresponds to a qualitative documentary design with a descriptive-analytical approach, based on a systematic literature review of publications from 2016 to 2026 in databases such as PubMed, SciELO, ScienceDirect, and Cochrane, using MeSH terms in both Spanish and English. Results indicate that models such as ResNet, DenseNet, and EfficientNet, trained on databases such as ChestX-ray14 and MIMIC-CXR, achieve AUC values above 0.85 in COPD classification, although challenges remain regarding model opacity (black box), population generalization, and ethical considerations for clinical implementation. It is concluded that AI represents a valuable diagnostic complement for chest radiology in COPD, provided its use is accompanied by clear regulatory frameworks and the active participation of the radiological technologist as a technological auditor.

**Keywords:** COPD, artificial intelligence, chest X-ray, deep learning, radiological diagnosis.

## Contenido

Introducción .....	8
Planteamiento del Problema .....	11
Justificación .....	13
Objetivos.....	15
Objetivo General .....	15
Objetivos Específicos .....	15
Marco Teórico.....	16
Fundamentos de la Enfermedad Pulmonar Obstructiva Crónica .....	16
Contexto Epidemiológico.....	17
Fisiopatología: Limitación del Flujo Aéreo, Enfisema y Bronquitis Crónica.....	18
El Rol de la Radiografía de Tórax en el Contexto de la EPOC.....	19
Otras Modalidades de Imagen en EPOC.....	20
Fundamentos Físicos de la Radiografía de Tórax en la EPOC .....	21
<i>Principios de Formación de la Imagen Radiológica .....</i>	<i>21</i>
<i>Parámetros Técnicos y Calidad Diagnóstica.....</i>	<i>21</i>
<i>Hallazgos Radiológicos de la EPOC en Radiografía de Tórax.....</i>	<i>23</i>
<i>Limitaciones de la Radiografía Convencional Frente al TC en EPOC....</i>	<i>24</i>
Inteligencia Artificial en Radiología: Fundamentos Tecnológicos.....	25
<i>Definición y Evolución Histórica de la IA en Medicina .....</i>	<i>25</i>
<i>Tipos de Aprendizaje Automático Aplicados a Imagen Médica .....</i>	<i>26</i>
<i>Redes Neuronales Convolucionales (CNN) .....</i>	<i>27</i>
<i>Transfer Learning y Arquitecturas de Referencia.....</i>	<i>28</i>

<i>Bases de Datos Públicas en Investigación</i> .....	29
Aplicaciones de la IA en el Diagnóstico Radiológico de la EPOC.....	30
<i>Detección y Clasificación Mediante Radiografía de Tórax</i> .....	30
<i>Estadificación de la Severidad Mediante TC Cuantitativa</i> .....	31
<i>Modelos Multimodales</i> .....	32
<i>Comparación de Rendimiento de Algoritmos</i> .....	33
<i>IA Explicable (XAI) en Radiología: Grad-CAM y LIME</i> .....	33
Limitaciones y Desafíos de la IA en el Diagnóstico de EPOC .....	35
<i>Calidad y Representatividad de los Datos de Entrenamiento</i> .....	35
<i>Generalización entre Instituciones y Poblaciones</i> .....	35
<i>El Problema de la “Caja Negra”: Opacidad e Interpretabilidad</i> .....	36
<i>Consideraciones Éticas y Regulatorias</i> .....	37
<i>Perspectiva Latinoamericana y Colombiana</i> .....	38
Rol del Tecnólogo en Radiología ante la Inteligencia Artificial.....	38
<i>Evolución del Perfil Profesional</i> .....	38
<i>Competencias Necesarias para la Era de la IA</i> .....	39
Marco Metodológico.....	41
Tipo y Diseño de Investigación.....	41
Estrategia de Búsqueda Bibliográfica .....	41
Descriptores y Operadores Booleanos .....	42
Criterios de Inclusión y Exclusión .....	42
<i>Criterios de Inclusión</i> .....	42
<i>Criterios de Exclusión</i> .....	43

Proceso de Selección de Literatura .....	43
<i>Fase 1 - Identificación</i> .....	43
<i>Fase 2 - Cribado por Título y Resumen</i> .....	43
<i>Fase 3 - Evaluación de Texto Completo</i> .....	43
<i>Fase 4 - Inclusión Final</i> .....	44
Resultados .....	45
Hallazgos sobre la EPOC en Radiografía Convencional y el Papel de la IA.....	45
Comparación de Modelos de IA.....	45
Limitaciones Identificadas en la Literatura .....	46
<i>Limitaciones Metodológicas</i> .....	47
<i>Limitaciones de Representatividad</i> .....	47
<i>Limitaciones Técnicas</i> .....	47
Conclusiones .....	49
Referencias Bibliográficas .....	52

**Lista de Tablas**

<b>Tabla 1</b> <i>Comparación de Modelos de IA</i> .....	45
----------------------------------------------------------	----

## Introducción

La enfermedad pulmonar obstructiva crónica (EPOC) representa una de las cargas de morbimortalidad más significativas del siglo XXI. De acuerdo con la Organización Mundial de la Salud (OMS, 2024), la EPOC es actualmente la cuarta causa de muerte en el mundo, responsable de aproximadamente 3,5 millones de defunciones en 2021, cifra que equivale al 5% de todas las muertes globales. Esta carga recae de manera desproporcionada sobre los países de ingreso mediano y bajo, donde casi el 90% de las muertes por EPOC ocurren en menores de 70 años, lo que refleja no solo la magnitud del problema sino también la inequidad en el acceso a diagnóstico y tratamiento oportuno (OMS, 2024).

Desde una perspectiva epidemiológica, Boers et al. (2023) proyectan que la prevalencia global de la EPOC, calculada en aproximadamente 480 millones de personas en 2020, podría alcanzar los 591 millones de casos para el año 2050, lo que representa un incremento del 23% en el número de afectados. Este crecimiento es especialmente pronunciado en los países de renta media y baja, donde la confluencia del tabaquismo, la contaminación del aire interior por combustión de biomasa y la exposición ambiental crónica eleva el riesgo de desarrollar la enfermedad, a menudo sin posibilidad de diagnóstico temprano.

Paradójicamente, a pesar de esta magnitud epidemiológica, la EPOC continúa siendo una enfermedad mayoritariamente subdiagnosticada. Según Centner et al. (2023), se estima que más del 70% de los individuos con EPOC a nivel mundial no han recibido un diagnóstico formal, lo que implica que una vasta mayoría de los afectados no recibe tratamiento ni seguimiento adecuado. Este fenómeno responde, en parte, a que el diagnóstico de certeza requiere la realización de espirometría con prueba broncodilatadora, un procedimiento que exige equipamiento especializado, personal entrenado y la colaboración activa del paciente,

condiciones no siempre disponibles en contextos de atención primaria, especialmente en América Latina.

En Colombia, el panorama no dista de la realidad global. Gil Rojas et al. (2019) estimaron la prevalencia de EPOC en Colombia a partir del Registro Individual de Prestaciones de Servicios de Salud (RIPS), evidenciando que la enfermedad genera una carga considerable sobre el sistema de salud, con hospitalizaciones frecuentes y alta mortalidad asociada. Bastidas et al. (2024) identificaron factores relacionados con la mortalidad por EPOC en población colombiana, señalando que la cronicidad de la enfermedad, la comorbilidad cardiovascular y el retraso diagnóstico son determinantes críticos del pronóstico. A esto se suma que Colombia concentra importantes grupos poblacionales rurales con uso doméstico de biomasa para cocción, lo que representa un factor de riesgo adicional frecuentemente subestimado en los sistemas de vigilancia epidemiológica.

Frente a este escenario, la incorporación de la inteligencia artificial (IA) en el análisis de imágenes médicas se presenta como una transformación tecnológica con alto potencial para mejorar la detección de la EPOC. La radiografía de tórax, como estudio de imagen de primera línea y amplia disponibilidad incluso en entornos de recursos limitados, constituye el terreno ideal para la aplicación de modelos de aprendizaje profundo. Las redes neuronales convolucionales (CNN) han demostrado capacidad para identificar patrones radiológicos sutiles asociados a la EPOC como la hiperinflación pulmonar, el aplanamiento diafragmático y la hiperclaridad, con un rendimiento que se aproxima o incluso supera al del radiólogo humano en condiciones experimentales (Yang et al., 2024; Dardouri, 2025).

Hosny et al. (2018) señalaron que la IA en radiología no solo tiene el potencial de mejorar la precisión diagnóstica, sino de transformar los flujos de trabajo clínicos, reducir el

tiempo de respuesta e identificar hallazgos que el ojo humano puede pasar por alto. Esta visión ha sido reforzada por Esteva et al. (2019), quienes documentaron que los modelos de aprendizaje profundo alcanzan un desempeño competitivo o superior en múltiples tareas de clasificación de imágenes médicas cuando se dispone de conjuntos de datos representativos y metodologías de entrenamiento robustas.

No obstante, la integración de la IA en el diagnóstico radiológico no está exenta de complejidades. La opacidad de los algoritmos, la dependencia de datos de entrenamiento representativos, las disparidades en la disponibilidad de infraestructura tecnológica y las consideraciones éticas sobre el sesgo algorítmico representan desafíos que deben abordarse con rigor antes de que estos sistemas puedan desplegarse de forma generalizada en entornos clínicos reales (Mehrabi et al., 2021; Albisua & Pacheco, 2024).

En este contexto, el presente trabajo de revisión documental se justifica por la necesidad de sintetizar el estado del arte sobre el uso de IA para el diagnóstico radiológico de la EPOC, con énfasis en la radiografía de tórax como modalidad accesible y de amplia cobertura poblacional. Además, se busca reflexionar sobre el rol emergente del tecnólogo en radiología como actor clave en la validación, supervisión y auditoría de los sistemas de IA aplicados a la imagen médica, una dimensión que adquiere particular relevancia en el contexto colombiano y latinoamericano.

## Planteamiento del Problema

La EPOC es una enfermedad prevenible y tratable que, sin embargo, continúa siendo diagnosticada tardíamente en la gran mayoría de los casos. El subdiagnóstico constituye el nodo central del problema: se estima que más del 70% de las personas con EPOC en el mundo no se han diagnosticado formalmente (Centner et al., 2023), lo que tiene consecuencias directas sobre la calidad de vida, la progresión de la enfermedad y los costos del sistema de salud.

El estándar diagnóstico actual para la EPOC es la espirometría con prueba broncodilatadora, la cual exige un cociente FEV1/FVC inferior a 0,70 en fase posbroncodilatadora para confirmar el diagnóstico (GOLD, 2024). Si bien este criterio es específico, su aplicación está limitada por múltiples factores: requiere equipamiento especializado, personal debidamente capacitado, condiciones ambientales controladas y la colaboración activa del paciente. En regiones rurales de Colombia y de otros países de América Latina, la espirometría es frecuentemente inaccesible o no está disponible en los centros de atención primaria, lo que genera una brecha diagnóstica estructural (Gil Rojas et al., 2019).

La radiografía de tórax convencional, aunque no forma parte de los criterios diagnósticos formales de la EPOC, es la modalidad de imagen de mayor disponibilidad en todos los niveles del sistema de salud y constituye, en la práctica clínica cotidiana, el primer acercamiento imagenológico al paciente con síntomas respiratorios. Sin embargo, su sensibilidad para detectar estadios tempranos de la EPOC es limitada; los hallazgos radiológicos característicos, por ejemplo, hiperinflación, aplanamiento diafragmático, hiperclaridad pulmonar, suelen manifestarse en fases avanzadas de la enfermedad, cuando el daño estructural ya es significativo (Cahn et al., 2020; Pompe & Mohamed Hoesein, 2021).

La tomografía computarizada (TC) de tórax, por su parte, ofrece una sensibilidad considerablemente mayor para cuantificar el enfisema, identificar atrapamiento aéreo y caracterizar las alteraciones bronquiales propias de la EPOC; sin embargo, su costo elevado, la exposición a radiación ionizante de mayor magnitud y su limitada disponibilidad en contextos de recursos restringidos impiden su uso rutinario como herramienta de tamización (Tanabe & Hirai, 2021).

Ante estas limitaciones, el potencial de la inteligencia artificial, específicamente los modelos de aprendizaje profundo para analizar radiografías de tórax y detectar patrones radiológicos compatibles con EPOC ofrece una posibilidad genuina para mejorar el diagnóstico temprano. Algoritmos entrenados sobre miles o millones de imágenes anotadas son capaces de identificar sutilezas visuales que escapan al análisis visual humano convencional, con un rendimiento que puede superar significativamente el de la interpretación manual no asistida (Yang et al., 2024; Raza et al., 2025). En este contexto, se identifica la siguiente pregunta de investigación

¿De qué manera los algoritmos de inteligencia artificial aplicados a la radiografía de tórax contribuyen al diagnóstico temprano de la enfermedad pulmonar obstructiva crónica?

## Justificación

La investigación sobre la aplicación de IA al diagnóstico radiológico de la EPOC se encuentra en plena expansión. En los últimos cinco años, se ha producido un incremento sostenido en el número de publicaciones que evalúan el rendimiento de modelos de aprendizaje profundo en la detección y estadificación de la EPOC a partir de radiografías de tórax y tomografías computarizadas. Estudios como los de Yang et al. (2024), Chen et al. (2024) y Lin et al. (2025) reportan métricas de desempeño, sensibilidad, especificidad, área bajo la curva (AUC), que consolidan a la IA como herramienta diagnóstica de alto valor científico. Sin embargo, la mayoría de estas investigaciones se han desarrollado en contextos de países de alta renta, con bases de datos de entrenamiento poco representativas de la diversidad étnica y demográfica de América Latina. La revisión documental del presente trabajo contribuye a sistematizar este conocimiento y a identificar las brechas de investigación que deben ser abordadas desde la perspectiva latinoamericana.

Desde la perspectiva clínica, cualquier herramienta que permita mejorar la tasa de detección temprana de la EPOC tiene un impacto directo sobre el pronóstico de los pacientes. El diagnóstico en estadios GOLD I o II, antes de que la limitación del flujo aéreo sea severa, permite implementar intervenciones farmacológicas y no farmacológicas que ralentizan la progresión de la enfermedad, reducen las exacerbaciones y disminuyen la mortalidad (GOLD, 2024). La radiografía de tórax, integrada con algoritmos de IA, podría operar como un tamiz que genere alertas diagnósticas en entornos donde la espirometría no está disponible, derivando a los pacientes con probabilidad elevada de EPOC hacia una confirmación espirométrica, optimizando así el uso de los recursos diagnósticos disponibles.

La EPOC afecta de manera desproporcionada a poblaciones vulnerables: trabajadores rurales expuestos al humo de biomasa, personas en situación de pobreza con limitado acceso a atención médica, y adultos mayores con comorbilidades múltiples. En Colombia, esta realidad se expresa en la persistente subestimación de la carga de EPOC en regiones con alta exposición al humo de leña y en la falta de datos epidemiológicos precisos a nivel departamental (Gil Rojas et al., 2019). Una herramienta de IA accesible y validada para el contexto latinoamericano podría contribuir a reducir estas inequidades diagnósticas. Sin embargo, su implementación debe acompañarse de reflexión ética sobre el sesgo algorítmico, la privacidad de los datos y el riesgo de desplazamiento del juicio clínico humano (Albisua & Pacheco, 2024; Mehrabi et al., 2021).

El tecnólogo en radiología ocupa una posición estratégica en el ecosistema de la imagen médica: es el profesional que adquiere las imágenes, garantiza la calidad técnica del estudio y opera los sistemas de información radiológica. En la era de la IA, este rol se amplía hacia la función de auditor tecnológico: el tecnólogo debe ser capaz de comprender los principios básicos de los algoritmos de IA, evaluar la coherencia de sus salidas diagnósticas, identificar artefactos o errores sistemáticos y actuar como mediador entre el sistema automatizado y el radiólogo o el clínico (Machacado-Rojas & AparicioPico, 2021). La revisión documental que propone este trabajo contribuye metodológicamente a construir una base conceptual sólida sobre la IA aplicada al diagnóstico de EPOC desde la perspectiva de la tecnología radiológica.

## **Objetivos**

### **Objetivo General**

Analizar la evidencia científica disponible sobre el uso de algoritmos de inteligencia artificial para el diagnóstico radiológico de la enfermedad pulmonar obstructiva crónica, identificando sus alcances, limitaciones y proyecciones clínicas.

### **Objetivos Específicos**

Describir los hallazgos radiológicos característicos de la EPOC en radiografía de tórax y su relación con los parámetros técnicos de adquisición de imagen.

Examinar los modelos de aprendizaje profundo utilizados para la detección y estadificación de la EPOC en imágenes radiológicas, contrastando su desempeño diagnóstico.

Identificar las limitaciones técnicas y éticas de los sistemas de IA aplicados al diagnóstico radiológico de la EPOC y proponer lineamientos para su implementación responsable.

## Marco Teórico

### Fundamentos de la Enfermedad Pulmonar Obstructiva Crónica

La enfermedad pulmonar obstructiva crónica (EPOC) se define como una enfermedad pulmonar crónica común, prevenible y tratable, caracterizada por síntomas respiratorios persistentes y limitación del flujo aéreo debida a anomalías de la vía aérea y/o de los alveolos, generalmente causada por una exposición significativa a partículas o gases nocivos (GOLD, 2024). Esta definición, establecida por la Global Initiative for Chronic Obstructive Lung Disease (GOLD), enfatiza la naturaleza heterogénea de la EPOC, que engloba dos entidades fisiopatológicas principales: el enfisema, caracterizado por la destrucción del parénquima alveolar y la bronquitis crónica, definida clínicamente por la presencia de tos con producción de esputo durante al menos tres meses al año por dos años consecutivos.

La clasificación de la severidad de la EPOC según la guía GOLD (2024) se basa en el cociente posbroncodilatador FEV1/FVC, siendo el criterio diagnóstico un valor inferior a 0,70. Una vez confirmada la obstrucción, la gravedad se establece con base en el porcentaje del FEV1 predicho: GOLD I (leve,  $FEV1 \geq 80\%$ ), GOLD II (moderada,  $50\% \leq FEV1 < 80\%$ ), GOLD III (grave,  $30\% \leq FEV1 < 50\%$ ) y GOLD IV (muy grave,  $FEV1 < 30\%$ ). Para la guía terapéutica, los pacientes estables se clasifican en grupos A, B o E, considerando la frecuencia e impacto de las exacerbaciones previas, de manera independiente al grado espirométrico (GOLD, 2024).

Esta clasificación funcional no captura plenamente la heterogeneidad clínica y estructural de la EPOC, razón por la cual múltiples investigaciones contemporáneas han explorado el fenotipado imagenológico mediante TC cuantitativa y, más recientemente, mediante modelos de IA que integran características radiomórficas con datos clínicos y funcionales (Chen et al., 2024; Lin et al., 2025).

## Contexto Epidemiológico

La magnitud epidemiológica de la EPOC es vasta y creciente. A nivel global, la prevalencia se estimó en 10,6% en 2020, equivalente a aproximadamente 480 millones de personas afectadas, y las proyecciones indican que para 2050 podría alcanzar los 591 millones de casos, representando un incremento relativo del 23% (Boers et al., 2023). Este crecimiento es especialmente marcado en mujeres, cuya prevalencia proyectada aumentaría del 7,8% al 8,33% en el mismo período, en parte por el incremento del tabaquismo femenino y la mayor exposición al humo de biomasa en países de renta baja y media.

En términos de mortalidad, la EPOC causó aproximadamente 3,5 millones de muertes en 2021, posicionándose como la cuarta causa de muerte en el mundo y la octava causa de mala salud en términos de años de vida ajustados por discapacidad (OMS, 2024). Casi el 90% de estas muertes ocurren en países de ingreso mediano y bajo, subrayando la inequidad en el acceso a diagnóstico y tratamiento.

En Colombia, los datos disponibles reflejan una carga significativa pero posiblemente subestimada. Gil Rojas et al. (2019) realizaron una estimación de la prevalencia de EPOC a partir del RIPS, encontrando una carga de enfermedad que genera demanda hospitalaria relevante y que afecta principalmente a mayores de 40 años con historia de tabaquismo o exposición a biomasa. Bastidas et al. (2024) analizaron factores relacionados con la mortalidad hospitalaria por EPOC en población colombiana, identificando que la presencia de comorbilidades cardiovasculares, el estadio avanzado de la enfermedad al momento del diagnóstico y las exacerbaciones frecuentes son los principales determinantes de mortalidad intrahospitalaria. Por su parte, Estrada-Álvarez et al. (2020) validaron en población colombiana

el puntaje de valoración de la gravedad de la EPOC, contribuyendo a la disponibilidad de herramientas de estratificación de riesgo adaptadas al contexto local.

Un elemento particularmente relevante para Colombia es el papel del humo de biomasa como factor etiológico de la EPOC. A diferencia de los países de alta renta, donde el tabaquismo explica más del 70% de los casos, en Colombia y otros países latinoamericanos la exposición al humo de leña y carbón vegetal en cocinas domésticas especialmente en zonas rurales, contribuye de manera significativa al desarrollo de EPOC, particularmente en mujeres (Centner et al., 2023; OMS, 2024). Esta particularidad fenotípica de la EPOC asociada a biomasa ha recibido atención creciente en la literatura científica, aunque su caracterización imagenológica y su respuesta a los algoritmos de IA entrenados principalmente con datos de fumadores permanece como un área de investigación abierta.

### **Fisiopatología: Limitación del Flujo Aéreo, Enfisema y Bronquitis Crónica**

La fisiopatología de la EPOC se organiza en torno a dos mecanismos que con frecuencia coexisten y se potencian mutuamente: la destrucción alveolar (enfisema) y la inflamación de la vía aérea (bronquitis crónica). La exposición crónica a agentes irritantes como humo de tabaco, biomasa, contaminantes ambientales, desencadena una respuesta inflamatoria anómala en las vías aéreas y el parénquima pulmonar, mediada principalmente por neutrófilos, macrófagos y linfocitos CD8+, que liberan proteasas (elastasa, metaloproteinasas de la matriz) capaces de destruir el tejido conectivo alveolar (GOLD, 2024).

La destrucción del parénquima alveolar en el enfisema conduce a la formación de espacios aéreos anormalmente grandes con pérdida de las paredes alveolares. Este proceso tiene dos consecuencias funcionales fundamentales: la reducción de la superficie de intercambio gaseoso y la pérdida del retroceso elástico pulmonar, que es el mecanismo responsable de

mantener abierta la vía aérea pequeña durante la espiración. Cuando el retroceso elástico disminuye, las vías aéreas pequeñas tienden a colapsar prematuramente durante la espiración, atrapando aire en los pulmones y generando hiperinflación dinámica (Tanabe & Hirai, 2021).

Paralelamente, la bronquitis crónica implica hipertrofia de las glándulas mucosas, hipersecreción de moco, engrosamiento de la pared bronquial e inflamación de la mucosa, todos ellos factores que reducen el diámetro de la luz bronquial y aumentan la resistencia al flujo aéreo. Desde el punto de vista radiológico, estos cambios se traducen en el engrosamiento de las paredes bronquiales visible en la radiografía de tórax y en la TC, donde se pueden cuantificar parámetros como el porcentaje de pared bronquial (%WA) y el espesor relativo de la pared (Pi10) (Chen et al., 2024).

La hiperinflación pulmonar resultante, tanto estática como dinámica, es la manifestación funcional más característica de la EPOC avanzada y la que produce los hallazgos radiológicos más reconocibles: aumento del diámetro anteroposterior del tórax, aplanamiento de los hemidiafragmas y horizontalización de las costillas, signos que los modelos de IA han aprendido a identificar con notable precisión (Yang et al., 2024).

### **El Rol de la Radiografía de Tórax en el Contexto de la EPOC**

La radiografía de tórax no forma parte de los criterios diagnósticos formales de la EPOC establecidos por la guía GOLD, sin embargo, tiene un papel fundamental como herramienta de apoyo clínico en varios contextos específicos: en la evaluación de las exacerbaciones agudas para descartar causas alternativas como la neumonía o el neumotórax, en la detección de comorbilidades como la insuficiencia cardíaca congestiva, y en la orientación inicial hacia el diagnóstico diferencial en pacientes con síntomas respiratorios crónicos (Cahn et al., 2020).

Aunque su sensibilidad para detectar EPOC en estadios tempranos es baja, estudios reportan sensibilidades del 40-70% con especificidades variables. La radiografía de tórax tiene la ventaja de ser la modalidad de imagen más accesible, de menor costo, de menor dosis de radiación y más extendida en todos los niveles del sistema de salud. En un contexto donde la espirometría no está disponible, la radiografía de tórax interpretada con el apoyo de sistemas de IA podría constituir una herramienta de primer nivel para identificar pacientes con alta probabilidad de EPOC y derivarlos hacia confirmación diagnóstica formal (Yang et al., 2024).

### **Otras Modalidades de Imagen en EPOC**

La tomografía computarizada (TC) de tórax, especialmente la TC de baja dosis, ofrece una sensibilidad muy superior a la radiografía convencional para la detección y cuantificación de los cambios estructurales asociados a la EPOC. La TC permite caracterizar el tipo y distribución del enfisema (centroacinar, panacinar, paraseptal), cuantificar el porcentaje de atenuación pulmonar por debajo de -950 HU (LAA-950, indicador de enfisema), medir el área de sección transversal de los bronquios y calcular índices de atrapamiento aéreo comparando imágenes en inspiración y espiración (Tanabe & Hirai, 2021; Pompe & Mohamed Hoesein, 2021).

Técnicas aún más avanzadas incluyen la TC por contraste de fase (dark-field CT), que Willer et al. (2021) han evaluado para la detección y cuantificación del enfisema en pacientes con EPOC, obteniendo resultados prometedores en la identificación de cambios microestructurales del parénquima que la TC convencional no puede detectar. La resonancia magnética pulmonar, aunque sin radiación ionizante, enfrenta desafíos técnicos importantes como la baja densidad de protones en el pulmón, artefactos por movimiento, que limitan su aplicación rutinaria en EPOC, aunque el uso de gases hiperpolarizados como el helio-3 o el xenón-129 está siendo investigado para la evaluación funcional de la ventilación pulmonar.

## **Fundamentos Físicos de la Radiografía de Tórax en la EPOC**

### ***Principios de Formación de la Imagen Radiológica***

La radiografía de tórax se basa en la interacción de los rayos X, radiación electromagnética de alta energía, con los tejidos del organismo. Al atravesar el tórax, los fotones de rayos X interactúan con la materia por dos mecanismos principales: el efecto fotoeléctrico, predominante a energías bajas ( $< 30$  keV), y la dispersión Compton, predominante en el rango de energías diagnósticas (25-150 keV) (Bushberg et al., 2020). En el efecto fotoeléctrico, el fotón es completamente absorbido por el átomo y transfiere su energía a un electrón orbital, que es expulsado; esta interacción es muy dependiente del número atómico del material ( $Z^3$ ), razón por la cual estructuras con alto  $Z$  como el hueso (calcio,  $Z=20$ ) o el contraste de bario, atenúan intensamente los rayos X. En el efecto Compton, el fotón interactúa con un electrón libre o poco ligado, se desvía con pérdida parcial de energía y el electrón es expulsado; esta interacción depende principalmente de la densidad electrónica del material y es la dominante en tejidos blandos a voltajes diagnósticos (Bushberg et al., 2020).

La imagen radiológica resultante refleja la distribución espacial de la atenuación de los rayos X en el tórax: el pulmón, con su alto contenido de aire (baja densidad, bajo  $Z$ ), atenúa muy poco los rayos X y aparece radiotransparente (negro); el mediastino y los tejidos blandos atenúan de manera intermedia y aparecen en tonos grises; el hueso cortical atenúa intensamente y aparece radiopaco (blanco) (Bushberg et al., 2020).

### ***Parámetros Técnicos y Calidad Diagnóstica***

La calidad diagnóstica de una radiografía de tórax depende críticamente de los parámetros técnicos de adquisición, los cuales deben ajustarse para equilibrar la adecuada visualización de las estructuras con la optimización de la dosis de radiación al paciente, principio

conocido como ALARA (As Low As Reasonably Achievable) (Bushberg et al., 2020). Los parámetros fundamentales son:

**Kilovoltaje pico (kVp):** Determina la calidad (energía) del haz de rayos X. En radiografía de tórax, se emplean valores altos (110-125 kVp) para obtener un haz con mayor poder de penetración, lo que reduce el contraste, pero mejora la visualización de estructuras superpuestas como el mediastino posterior. El uso de alto kVp disminuye también la dosis de radiación al paciente.

**Miliamperaje por segundo (mAs):** Determina la cantidad (número de fotones) del haz. A mayor mAs, mayor densidad de fotones, lo que incrementa la señal y reduce el ruido cuántico, pero también aumenta la dosis de radiación. En radiografía de tórax, los mAs se ajustan para obtener una exposición adecuada según la constitución del paciente.

**Distancia foco-película/detector:** La radiografía de tórax estándar se realiza con una distancia de 180 cm (posición posteroanterior, PA), lo que minimiza la magnificación de las estructuras mediastínicas y cardíacas.

**Posición y proyección:** La proyección PA en inspiración máxima es la estándar; la proyección lateral complementa la evaluación de estructuras retrocardíacas y del espacio retroesternal.

Los criterios de calidad en radiografía de tórax incluyen: adecuada inspiración (visibilidad del 10.º arco costal posterior), simetría (ausencia de rotación del paciente, valorada por la equidistancia de las clavículas respecto a las apófisis espinosas), penetración adecuada (visualización de los cuerpos vertebrales torácicos a través de la sombra cardíaca) y ausencia de artefactos de movimiento (Bushberg et al., 2020). Estos criterios son fundamentales porque

afectan directamente la confiabilidad de los hallazgos radiológicos y, por extensión, la precisión de los algoritmos de IA que interpretan estas imágenes.

### ***Hallazgos Radiológicos de la EPOC en Radiografía de Tórax***

Los hallazgos radiológicos de la EPOC en la radiografía de tórax convencional son consecuencia directa de los cambios fisiopatológicos descritos previamente. Aunque ninguno es patognomónico, todos pueden aparecer en otras condiciones, su presencia conjunta en el contexto clínico apropiado orienta fuertemente hacia el diagnóstico (Pompe & Mohamed Hoesein, 2021; Cahn et al., 2020).

**Hiperinflación pulmonar:** Es el hallazgo más característico y radiológicamente relevante. Se manifiesta como el aumento del diámetro anteroposterior del tórax (con frecuencia mayor de 2,5 cm en la proyección lateral), el aplanamiento y descenso de los hemidiafragmas (el hemidiafragma derecho se proyecta normalmente en el nivel del sexto arco costal anterior; en la EPOC avanzada puede descender al séptimo u octavo), la horizontalización de las costillas (con reducción de los ángulos costodiafragmáticos), el aumento del espacio retroesternal y la hiperclaridad pulmonar generalizada. Yang et al. (2024) demostraron que los modelos de IA entrenados sobre radiografías de tórax son capaces de cuantificar estos signos de hiperinflación con alta precisión, utilizando la posición diafragmática como uno de los biomarcadores imagenológicos primarios.

**Hiperclaridad pulmonar:** La destrucción del parénquima alveolar en el enfisema reduce la densidad tisular del pulmón, lo que produce áreas de mayor transparencia radiológica. En la radiografía convencional, la hiperclaridad puede manifestarse de forma difusa (en el enfisema panlobulillar, típico de la deficiencia de alfa-1 antitripsina) o predominantemente en los campos

superiores (en el enfisema centroacinar, asociado al tabaquismo) (Pompe & Mohamed Hoesein, 2021).

**Redistribución vascular:** En la EPOC con enfisema predominante, la destrucción del lecho capilar alveolar reduce el calibre de los vasos pulmonares periféricos (oligohemia), lo que produce una apariencia de pulmón “limpio” con reducción del patrón vascular en los lóbulos afectados. Paradójicamente, en la EPOC con predominio de bronquitis crónica, puede observarse un incremento del patrón broncovascular periférico como expresión de la inflamación crónica de la pared bronquial (Pompe & Mohamed Hoesein, 2021).

**Engrosamiento de paredes bronquiales:** Visible en la radiografía de tórax como líneas paralelas engrosadas alrededor de los bronquios visibles en sección longitudinal (“imágenes en vía de tren”), este hallazgo refleja el engrosamiento inflamatorio de la pared bronquial propio de la bronquitis crónica (Pompe & Mohamed Hoesein, 2021).

**Signos de hipertensión pulmonar:** En estadios avanzados de EPOC, la vasoconstricción hipóxica crónica y la destrucción del lecho vascular pulmonar pueden generar hipertensión pulmonar. Radiológicamente, esto se manifiesta como prominencia de las arterias pulmonares centrales con contrastada oligohemia periférica, ampliación del hilio pulmonar y eventual cardiomegalia por cor pulmonale (Pompe & Mohamed Hoesein, 2021).

### ***Limitaciones de la Radiografía Convencional Frente al TC en EPOC***

La radiografía de tórax tiene limitaciones inherentes en el contexto diagnóstico de la EPOC. Su sensibilidad para detectar la enfermedad en estadios leves (GOLD I-II) es baja, dado que los cambios estructurales iniciales son demasiado sutiles para ser visualizados en la proyección bidimensional de la radiografía convencional. La TC de alta resolución permite detectar enfisema cuando este representa menos del 1% del parénquima pulmonar, mientras que

la radiografía convencional solo detecta el enfisema cuando supera un umbral significativo de destrucción tisular (Tanabe & Hirai, 2021). Asimismo, la superposición de estructuras en la proyección bidimensional limita la evaluación de regiones anatómicamente complejas, como el lóbulo medio derecho o el segmento lingular.

Sin embargo, la radiografía sigue siendo insustituible como herramienta de primer nivel por su accesibilidad, rapidez, bajo costo y la posibilidad de realizarla incluso en pacientes de difícil movilización (Cahn et al., 2020). En el contexto de la IA, sus limitaciones inherentes representan precisamente el desafío que los modelos de aprendizaje profundo buscan superar (Yang et al., 2024).

## **Inteligencia Artificial en Radiología: Fundamentos Tecnológicos**

### ***Definición y Evolución Histórica de la IA en Medicina***

La inteligencia artificial puede definirse como el conjunto de tecnologías computacionales que permiten a los sistemas ejecutar tareas que normalmente requerirían inteligencia humana, incluyendo el reconocimiento de patrones, la toma de decisiones, el aprendizaje a partir de datos y la comprensión del lenguaje natural (AvilaTomás et al., 2020a). En medicina, la IA ha transitado por tres grandes etapas históricas: los sistemas expertos de las décadas de 1970-1990, basados en reglas codificadas manualmente; las técnicas estadísticas clásicas de aprendizaje automático de los años 1990-2010; y la era actual del aprendizaje profundo, iniciada en torno a 2012 con la irrupción de las redes neuronales convolucionales profundas en la competencia ImageNet (Hosny et al., 2018; Avila-Tomás et al., 2020b).

Hosny et al. (2018) señalan que la incorporación de la IA en radiología ha sido impulsada por tres factores convergentes: la disponibilidad de grandes conjuntos de datos etiquetados de imágenes médicas, el incremento exponencial de la capacidad computacional (especialmente

mediante unidades de procesamiento gráfico, GPU) y el desarrollo de arquitecturas de redes neuronales cada vez más eficientes. Esta convergencia ha permitido que los modelos de IA superen, en tareas específicas y bajo condiciones experimentales controladas, el desempeño diagnóstico de los radiólogos expertos en la identificación de patologías como el cáncer de mama, el cáncer de pulmón, la retinopatía diabética y la neumonía (Esteva et al., 2019).

### ***Tipos de Aprendizaje Automático Aplicados a Imagen Médica***

En el contexto del diagnóstico radiológico, los modelos de IA se organizan principalmente en torno a tres paradigmas de aprendizaje (Hosny et al., 2018; AvilaTomás et al., 2020b):

**Aprendizaje supervisado:** Es el paradigma dominante en diagnóstico por imagen. El modelo se entrena con un conjunto de pares imagen-etiqueta, donde las etiquetas son anotaciones realizadas por expertos (diagnósticos, segmentaciones, coordenadas de bounding boxes). Durante el entrenamiento, el modelo aprende a minimizar la diferencia entre su predicción y la etiqueta real mediante la retropropagación del gradiente del error. Al finalizar el entrenamiento, el modelo puede clasificar nuevas imágenes sin etiqueta. La calidad y representatividad del conjunto de entrenamiento es el factor más determinante del rendimiento del modelo en datos reales (Mehrabi et al., 2021).

**Aprendizaje no supervisado:** En ausencia de etiquetas, los modelos buscan estructura inherente en los datos. Técnicas como los autoencoders o el clustering basado en k-means pueden identificar subgrupos de pacientes con patrones de imagen similares, lo que resulta útil para el fenotipado de la EPOC y la identificación de endotipos radiológicos. Liu & Shen (2024) revisaron aplicaciones de aprendizaje no supervisado en la detección temprana de EPOC,

encontrando que estos modelos pueden identificar subgrupos de riesgo incluso en ausencia de diagnóstico confirmado por espirometría.

**Aprendizaje por refuerzo:** Un agente aprende a tomar decisiones secuenciales para maximizar una recompensa acumulada. Aunque menos explorado en radiología diagnóstica, tiene aplicaciones potenciales en la optimización de protocolos de adquisición de imagen y en la planificación automatizada de tratamientos (Avila-Tomás et al., 2020b).

### ***Redes Neuronales Convolucionales (CNN)***

Las redes neuronales convolucionales son la arquitectura de aprendizaje profundo dominante en el análisis de imágenes médicas. Su diseño imita, de forma simplificada, el procesamiento visual del córtex cerebral: capas sucesivas de neuronas artificiales aplican filtros (kernels) de convolución sobre la imagen de entrada, extrayendo características de complejidad creciente en cada nivel de profundidad. Las primeras capas capturan características simples como bordes y texturas; las capas intermedias detectan formas y estructuras; y las capas más profundas integran estas características en representaciones de alto nivel semánticamente significativas para la tarea de clasificación (Hosny et al., 2018).

Una CNN típica para clasificación de imágenes médicas se compone de bloques alternados de capas convolucionales (aplicación de filtros), capas de activación no lineal (ReLU, función rectificadora), capas de pooling (reducción espacial de las representaciones), capas de normalización por lotes (batch normalization) y, al final de la red, capas totalmente conectadas (fully connected) que producen el vector de probabilidades de pertenencia a cada clase. El entrenamiento se realiza mediante descenso del gradiente estocástico (SGD o variantes como Adam) y la función de pérdida estándar para clasificación es la entropía cruzada (Esteva et al., 2019).

### ***Transfer Learning y Arquitecturas de Referencia***

El transfer learning o aprendizaje por transferencia es una estrategia fundamental en la aplicación de CNN a la imagen médica. Consiste en inicializar los pesos de la red a partir de un modelo preentrenado en un conjunto de datos masivo, típicamente ImageNet, con 1,4 millones de imágenes de objetos naturales y posteriormente afinar (fine-tuning) el modelo con el conjunto de datos médico de interés. Esta estrategia permite superar la limitación de los conjuntos de datos médicos, frecuentemente pequeños para el entrenamiento desde cero (Raza et al., 2025).

Las arquitecturas de referencia más utilizadas en diagnóstico por imagen de EPOC son:

**ResNet (He et al., 2016):** Introducción de conexiones residuales (skip connections) que permiten entrenar redes con decenas o centenares de capas sin el problema de desvanecimiento del gradiente. ResNet-50, ResNet-101 y ResNet-152 son variantes frecuentemente empleadas.

**DenseNet (Huang et al., 2017):** Conecta cada capa con todas las capas posteriores, favoreciendo la reutilización de características y reduciendo el número de parámetros. DenseNet-121 es la arquitectura de referencia en múltiples benchmarks de imagen médica, habiendo sido utilizada por CheXNet para la clasificación de patologías torácicas.

**VGG (Simonyan & Zisserman, 2014):** Arquitectura de profundidad uniforme con kernels de  $3 \times 3$ , notable por su simplicidad y buen rendimiento en transfer learning.

**EfficientNet (Tan & Le, 2019):** Escala de forma sistemática la profundidad, el ancho y la resolución de la red, logrando mayor eficiencia computacional con desempeño competitivo.

En el contexto específico de la EPOC, Yang et al. (2024) utilizaron una arquitectura CNN combinada con parámetros clínicos estructurados para mejorar el rendimiento en la detección y estadificación de la EPOC a partir de radiografías de tórax, obteniendo un AUC de 0,90 para la detección. Raza et al. (2025) evaluaron múltiples arquitecturas de transfer learning para la

clasificación de enfermedades pulmonares en radiografías de tórax, concluyendo que los modelos preentrenados en ImageNet y ajustados con datos clínicos superan consistentemente a los modelos entrenados desde cero cuando el conjunto de datos de entrenamiento es limitado.

### ***Bases de Datos Públicas en Investigación***

El desarrollo de modelos de IA para el análisis de imágenes torácicas ha sido impulsado decisivamente por la disponibilidad de grandes bases de datos públicas de acceso abierto (Johnson et al., 2019; Wang et al., 2017):

**ChestX-ray14 (NIH):** Contiene 112.120 radiografías de tórax de 30.805 pacientes, anotadas con 14 etiquetas de patología, incluyendo atelectasia, consolidación, efusión pleural, edema, enfisema, fibrosis, neumonía, neumotórax, masas y nódulos, entre otras. Fue desarrollada por Wang et al. (2017) y es una de las bases de referencia más utilizadas para benchmarking de modelos de clasificación.

**MIMIC-CXR:** Desarrollada por Johnson et al. (2019), contiene más de 370.000 imágenes de 227.827 estudios radiológicos de 64.588 pacientes del Hospital General de Massachusetts. Es notable por incluir informes radiológicos de texto libre, lo que permite el entrenamiento de modelos multimodales que integran imagen y lenguaje natural.

**COPDGene:** Base de datos multicéntrica específica para EPOC, que incluye TC de tórax, datos de espirometría, cuestionarios clínicos y datos de seguimiento a largo plazo de más de 10.000 fumadores actuales y exfumadores. Se ha utilizado extensamente para el desarrollo y validación de modelos de fenotipado de EPOC (Chen et al., 2024).

La representatividad de estas bases de datos es un aspecto crítico: en su gran mayoría están constituidas por imágenes de pacientes de países de alta renta, con predominio de etnias

caucásicas y asiáticas, lo que limita la generalización de los modelos a poblaciones latinoamericanas y africanas (Mehrabi et al., 2021; Centner et al., 2023).

## **Aplicaciones de la IA en el Diagnóstico Radiológico de la EPOC**

### ***Detección y Clasificación Mediante Radiografía de Tórax***

La aplicación más directamente relevante para el contexto clínico latinoamericano es la detección de la EPOC a partir de la radiografía de tórax convencional, dada su mayor disponibilidad respecto a la TC y su menor costo (Centner et al., 2023; Gil Rojas et al., 2019). Yang et al. (2024) publicaron un estudio fundamental en esta línea: desarrollaron un modelo de aprendizaje profundo que combina características de imagen extraídas de radiografías de tórax con parámetros clínicos estructurados (edad, sexo, índice de masa corporal, historia de tabaquismo) para la detección y estadificación de la EPOC. El modelo, basado en una arquitectura CNN con transfer learning, alcanzó un AUC de 0,90 para la clasificación binaria EPOC/no-EPOC, con una sensibilidad del 82% y una especificidad del 87% en el conjunto de validación independiente.

Dardouri (2025) evaluó un modelo de CNN profundo para la detección de múltiples enfermedades pulmonares en radiografías de tórax, logrando un AUC de 0,88 para la detección de hallazgos compatibles con enfisema. Raza et al. (2025) compararon múltiples arquitecturas de transfer learning para la clasificación de enfermedades pulmonares incluyendo EPOC, neumonía y tuberculosis encontrando que EfficientNet-B4 y DenseNet-121 ofrecían el mejor equilibrio entre rendimiento y eficiencia computacional.

Djellal et al. (2024) realizaron un análisis comparativo de algoritmos de aprendizaje automático, no solo de aprendizaje profundo, para el diagnóstico mejorado de EPOC, incluyendo Random Forest, SVM, XGBoost y redes neuronales, utilizando datos combinados de función

pulmonar y biomarcadores clínicos. Sus resultados indicaron que los modelos de ensemble, especialmente XGBoost combinado con parámetros espirométricos e imagenológicos, superan en precisión a los modelos univariados basados exclusivamente en imagen.

### ***Estadificación de la Severidad Mediante TC Cuantitativa***

La TC de tórax ha sido el campo más fértil para el desarrollo de modelos de IA aplicados a la EPOC. Chen et al. (2024) publicaron una revisión comprehensiva del estado del arte de la IA en TC de EPOC, abarcando la identificación, estadificación y cuantificación de la enfermedad. Los modelos de segmentación basados en U-Net y sus variantes permiten la delimitación automática del parénquima pulmonar, la cuantificación del porcentaje de pulmón con atenuación inferior a -950 HU (enfisema), el cálculo del atrapamiento aéreo (comparando inspiración/espriación) y la medición del área de sección transversal de los bronquios. Heussel et al. (2023) desarrollaron un modelo de aprendizaje profundo para la predicción de la gravedad de la EPOC en TC de tórax basado en la detección de anomalías cuantitativas, con correlación significativa con los parámetros espirométricos GOLD. Su modelo logró una correlación de Pearson de 0,76 con el FEV1% predicho, sugiriendo que los biomarcadores radiológicos cuantitativos derivados por IA pueden complementar y en algunos contextos, sustituir la evaluación espirométrica.

Lin et al. (2025) presentaron AutoCOPD, un modelo de aprendizaje automático multicentro para la detección de EPOC mediante medidas cuantitativas de TC pulmonar completa en inspiración, logrando un AUC de 0,94 en el conjunto de prueba independiente. Este modelo se destacó por su diseño multicéntrico, con datos de 1.738 pacientes procedentes de 11 centros hospitalarios, lo que incrementa significativamente la confianza en su capacidad de generalización respecto a modelos entrenados en datos de un único centro.

### ***Modelos Multimodales***

La integración de datos de múltiples fuentes como imagen radiológica, función pulmonar, biomarcadores séricos, datos clínicos y demográficos en modelos multimodales, representa la frontera más avanzada de la IA aplicada a la EPOC (Liu & Shen, 2024; Djellal et al., 2024). Liu & Shen (2024) realizaron una revisión narrativa sobre el uso del aprendizaje automático para la detección temprana de la EPOC, concluyendo que los modelos multimodales que integran imagen TC con datos espirométricos y clínicos consistentemente superan a los modelos que utilizan una sola fuente de información, con mejoras en el AUC de entre 0,05 y 0,15 unidades respecto a los modelos de imagen aislada.

Aseri (2025) revisó el papel de la IA y el aprendizaje automático en el manejo de la EPOC y el asma, destacando los avances en modelos de predicción de exacerbaciones que combinan datos de imagen, función pulmonar, registros electrónicos de salud y datos de dispositivos portátiles (wearables). Kurniawan et al. (2025) analizaron las perspectivas de la IA para revolucionar el manejo de la EPOC, señalando el potencial de los modelos de lenguaje de gran escala (LLMs) para integrar datos heterogéneos en recomendaciones clínicas contextualizadas.

Jadhav & Shingne (2026) propusieron un marco multimodal impulsado por IA para la detección y evaluación de la gravedad de la bronquitis crónica y la EPOC, combinando análisis de imagen, espirometría y datos demográficos en un pipeline de clasificación automatizada con alta precisión reportada en conjuntos de datos de prueba.

### ***Comparación de Rendimiento de Algoritmos***

El rendimiento de los modelos de IA en el diagnóstico de EPOC se evalúa mediante métricas estándar de clasificación binaria o multiclase ampliamente descritas en la literatura (Hosny et al., 2018; Mehrabi et al., 2021). Las principales son:

**Sensibilidad (recall):** Proporción de casos verdaderamente positivos que el modelo identifica correctamente. Una alta sensibilidad minimiza los falsos negativos, es decir, pacientes con EPOC no detectados.

**Especificidad:** Proporción de casos verdaderamente negativos identificados correctamente. Alta especificidad minimiza los falsos positivos, como diagnósticos incorrectos de EPOC en personas sanas.

**Área bajo la curva ROC (AUC):** Medida sintética del rendimiento de clasificación que integra todas las combinaciones posibles de sensibilidad/especificidad. Un AUC de 1,0 es perfecto; 0,5 equivale a la predicción aleatoria; valores superiores a 0,85 se consideran de buen rendimiento diagnóstico.

**F1-score:** Media armónica de precisión y sensibilidad, útil cuando las clases están desbalanceadas.

Los modelos revisados en la literatura reportan consistentemente AUC entre 0,82 y 0,94 para la detección de EPOC en radiografía de tórax y TC, con mayor rendimiento en TC que en radiografía (Yang et al., 2024; Lin et al., 2025; Djellal et al., 2024). La comparativa detallada de estos estudios se presenta en la sección de Resultados.

### ***IA Explicable (XAI) en Radiología: Grad-CAM y LIME***

Un aspecto crítico para la aceptación clínica de los modelos de IA en radiología es su capacidad de proporcionar explicaciones interpretables de sus predicciones. Los métodos de IA

explicable (XAI) buscan hacer transparente el proceso de toma de decisiones de los modelos de “caja negra” (Rehman et al., 2023).

**Grad-CAM (Gradient-weighted Class Activation Mapping):** Es el método de XAI más ampliamente utilizado en imagen médica. Genera mapas de calor (heatmaps) que señalan las regiones de la imagen que han contribuido más a la predicción del modelo. En el contexto de la EPOC, un heatmap de Grad-CAM en una radiografía de tórax debería activarse preferentemente sobre las regiones pulmonares hiperinfladas y sobre los hemidiafragmas aplanados, lo que permite al radiólogo o tecnólogo validar que el modelo está tomando decisiones basadas en características clínicamente relevantes (Rehman et al., 2023).

**LIME (Local Interpretable Model-agnostic Explanations):** Genera explicaciones locales de cada predicción perturbando el entorno de la imagen de entrada y observando cómo cambia la predicción del modelo. Es agnóstico respecto a la arquitectura del modelo, lo que lo hace aplicable a cualquier clasificador de caja negra.

Guo et al. (2024) evaluaron el desempeño de radiólogos en la interpretación de radiografías de tórax con y sin asistencia de IA, encontrando que el uso de sistemas de asistencia mejora significativamente la precisión diagnóstica, especialmente para radiólogos con menor experiencia. Rehman et al. (2023) desarrollaron un framework de IA explicable para la interpretación de enfermedades pulmonares en radiografías de tórax, utilizando Grad-CAM para proporcionar mapas de activación que correlacionan con los hallazgos clínicos esperados, lo que facilita la confianza clínica en el sistema.

## **Limitaciones y Desafíos de la IA en el Diagnóstico de EPOC**

### ***Calidad y Representatividad de los Datos de Entrenamiento***

La calidad de los datos de entrenamiento es la limitación más determinante del rendimiento de los modelos de IA en diagnóstico médico. Los sesgos presentes en el conjunto de entrenamiento, de selección, de medición, de etiquetado, se propagan inevitablemente al modelo entrenado, que los aprende como si fueran patrones genuinos (Mehrabi et al., 2021).

En el contexto de la EPOC, los sesgos más relevantes incluyen: la sobrerrepresentación de pacientes con EPOC avanzada (GOLD III-IV), ya que son quienes con mayor frecuencia son atendidos en centros hospitalarios donde se generan las imágenes utilizadas para entrenamiento; la subrepresentación de mujeres y de grupos étnicos no caucásicos en las bases de datos públicas principales (ChestX-ray14, MIMIC-CXR); y la variabilidad en los estándares de calidad de imagen entre diferentes centros, equipos y técnicos radiológicos (Centner et al., 2023). El proceso de etiquetado también introduce incertidumbre: la anotación de radiografías de tórax por radiólogos expertos presenta variabilidad interobservador significativa, especialmente para hallazgos sutiles como la discreta hiperinflación pulmonar o el engrosamiento leve de paredes bronquiales (Guo et al., 2024). Cuando el modelo se entrena sobre etiquetas ruidosas o inconsistentes, su rendimiento en datos externos puede ser inferior al reportado en el conjunto de validación interno (Mehrabi et al., 2021).

### ***Generalización entre Instituciones y Poblaciones***

La generalización de los modelos de IA, su capacidad para mantener el rendimiento cuando se aplican a datos procedentes de centros, equipos o poblaciones distintos a los utilizados en el entrenamiento, es uno de los desafíos técnicos más importantes y frecuentemente subestimados en la literatura (Liu & Shen, 2024). Múltiples estudios han demostrado que

modelos con excelente rendimiento en el conjunto de validación interno experimentan caídas significativas de AUC cuando se evalúan con datos de centros externos, fenómeno conocido como distributional shift o cambio de distribución.

En el contexto de la EPOC en América Latina, la ausencia de bases de datos públicas latinoamericanas representa una brecha crítica. Los algoritmos entrenados exclusivamente con datos de Estados Unidos, Europa o China pueden no capturar adecuadamente las particularidades radiológicas de la EPOC por biomasa que puede tener un fenotipo imagenológico diferente al de la EPOC por tabaquismo, ni las variaciones en los estándares técnicos de adquisición de imagen propios de los sistemas de salud latinoamericanos (Centner et al., 2023).

### ***El Problema de la “Caja Negra”: Opacidad e Interpretabilidad***

Los modelos de aprendizaje profundo, especialmente las CNN con millones de parámetros, son esencialmente cajas negras: sus mecanismos de toma de decisiones son matemáticamente opacos e ininterpretables para el clínico. Aunque los métodos de XAI como Grad-CAM ofrecen una ventana visual hacia las regiones de la imagen que el modelo considera relevantes, no proporcionan una explicación causal completa del razonamiento del algoritmo (Rehman et al., 2023).

Esta opacidad genera desconfianza en los clínicos, que con razón se preguntan si el modelo está tomando decisiones basadas en características radiológicas genuinamente relacionadas con la EPOC o en artefactos espurios presentes en el conjunto de entrenamiento, tales como textos en las imágenes, variaciones de calidad entre instituciones o diferencias en la posición del paciente (Rehman et al., 2023). Fernández-Villar et al. (2020) señalaron que la opacidad de los algoritmos de IA es uno de los principales obstáculos para su adopción en la

práctica radiológica, y que su resolución requiere no solo avances técnicos en XAI sino también marcos regulatorios que exijan transparencia en los sistemas de IA médica.

### ***Consideraciones Éticas y Regulatorias***

La implementación de sistemas de IA en el diagnóstico clínico plantea cuestiones éticas de primera magnitud que trascienden los aspectos técnicos. Albisua & Pacheco (2024) delimitan los límites éticos del uso de IA en medicina, identificando cuatro principios fundamentales

**Autonomía del paciente:** El paciente debe informarse cuando una IA participa en su diagnóstico

**Beneficencia:** El sistema debe demostrar beneficio neto para el paciente

**No maleficencia:** Los errores del sistema no deben causar daño al paciente

**Justicia:** El sistema no debe ampliar las desigualdades diagnósticas entre grupos poblacionales.

El sesgo algorítmico es la dimensión ética más documentada en la literatura: Mehrabi et al. (2021) revisaron exhaustivamente los tipos de sesgo en aprendizaje automático, clasificándolos en sesgos de datos (datos de entrenamiento no representativos), sesgos de representación (subgrupos poblacionales insuficientemente representados) y sesgos de evaluación (métodos de validación que no capturan el rendimiento real en condiciones de despliegue). En diagnóstico de EPOC, estos sesgos pueden manifestarse como peor rendimiento del modelo en pacientes de raza negra, en mujeres o en pacientes con EPOC por biomasa, generando inequidades diagnósticas que el sistema de IA podría amplificar en lugar de corregir.

Desde el punto de vista regulatorio, los sistemas de IA para diagnóstico médico son clasificados como dispositivos médicos de software (SaMD, Software as a Medical Device) y están sujetos a la regulación de las agencias nacionales de salud. En Estados Unidos, la FDA ha

aprobado más de 500 dispositivos de IA médica, pero la mayoría corresponden a tecnologías de alta renta y los marcos regulatorios latinoamericanos, incluyendo el colombiano, están aún en desarrollo (Lippi & Plebani, 2025).

### ***Perspectiva Latinoamericana y Colombiana***

La implementación de IA para el diagnóstico radiológico de EPOC en Colombia y América Latina enfrenta desafíos específicos que van más allá de los aspectos técnicos. En primer lugar, la infraestructura tecnológica de muchos centros de salud especialmente en zonas rurales y de difícil acceso, no está adaptada para la integración de sistemas de IA que requieren conectividad a internet, servidores de alto rendimiento o actualizaciones regulares de software. En segundo lugar, la formación del personal de salud en IA es aún incipiente, y la percepción de la tecnología puede ser de desconfianza o, por el contrario, de confianza excesiva (Mayer, 2023). Sin embargo, existen iniciativas prometedoras. El repositorio de la Universidad Nacional Abierta y a Distancia (UNAD) ha comenzado a documentar estudios sobre el impacto de la IA en la radiología colombiana, incluyendo trabajos sobre el rol del tecnólogo en radiología ante estos cambios tecnológicos (Machacado-Rojas & AparicioPico, 2021). Comellas et al. (2023) realizaron una revisión comprehensiva de la IA aplicada a imagen pulmonar, subrayando la necesidad de incluir conjuntos de datos latinoamericanos en los estudios de validación internacional para asegurar la equidad y la aplicabilidad de los modelos en estas regiones.

### **Rol del Tecnólogo en Radiología ante la Inteligencia Artificial**

#### ***Evolución del Perfil Profesional***

La irrupción de la inteligencia artificial en la radiología diagnóstica está generando una transformación profunda del perfil profesional del tecnólogo en radiología. Este profesional, cuya función tradicional ha sido la adquisición técnica de imágenes médicas garantizando la

correcta posición del paciente, la selección de los parámetros de exposición y el procesamiento de las imágenes, se enfrenta ahora a un entorno radicalmente nuevo en el que los sistemas de IA automatizan parte de las tareas de interpretación, detección de hallazgos y priorización de estudios (Machacado-Rojas & Aparicio-Pico, 2021).

Esta transformación no supone la obsolescencia del tecnólogo, sino la redefinición y ampliación de sus competencias. En la era de la IA, el tecnólogo se convierte en un actor crítico en múltiples dimensiones del flujo de trabajo radiológico que los sistemas automatizados no pueden reemplazar: la gestión del contacto humano con el paciente, la garantía de la calidad técnica de las imágenes que alimentan los algoritmos, la supervisión crítica de los resultados del sistema de IA y la comunicación interdisciplinaria sobre los hallazgos diagnósticos (Fernández-Villar et al., 2020).

Kornafeld et al. (2025) analizaron el rol de la IA en la neumología intervencionista, señalando que la presencia de un profesional formado en el manejo de estos sistemas es indispensable para garantizar que los resultados generados por la IA sean clínicamente coherentes y que los errores sistemáticos sean detectados y reportados.

### ***Competencias Necesarias para la Era de la IA***

La formación del tecnólogo en radiología para la era de la IA requiere la incorporación de nuevas competencias que trascienden el conocimiento técnico tradicional (Mayer, 2023; Machacado-Rojas & Aparicio-Pico, 2021):

Comprensión de los principios básicos del aprendizaje automático y profundo, las métricas de evaluación de modelos (sensibilidad, especificidad, AUC), los conceptos de entrenamiento y validación, y los principales tipos de sesgos algorítmicos.

**Análisis crítico de la evidencia científica:** Capacidad para leer e interpretar críticamente publicaciones científicas sobre sistemas de IA aplicados a radiología, evaluando la solidez metodológica de los estudios y la validez externa de sus resultados.

**Ética profesional en entornos tecnológicos:** Comprensión de las implicaciones éticas del uso de IA en diagnóstico médico, incluyendo la privacidad de los datos, el consentimiento informado en el contexto de la IA y la responsabilidad profesional ante errores del sistema.

**Comunicación interdisciplinaria:** Habilidad para comunicarse de forma efectiva con radiólogos, clínicos e ingenieros de software sobre los resultados del sistema de IA, sus limitaciones y sus implicaciones para la toma de decisiones clínicas.

Mayer (2023) señala que la formación de los profesionales de la salud en IA debe incluir tanto aspectos técnicos como reflexión crítica sobre sus limitaciones y sus implicaciones para la práctica clínica, subrayando que el objetivo no es formar tecnólogos que programen modelos de IA, sino profesionales que los utilicen de manera responsable, crítica y competente.

## Marco Metodológico

### Tipo y Diseño de Investigación

El presente trabajo es una investigación documental de enfoque cualitativo y diseño descriptivo-analítico. La investigación documental es definida como el proceso sistemático de recolección, organización y análisis de información obtenida de fuentes documentales, artículos científicos, revisiones sistemáticas, guías de práctica clínica, libros de texto, con el propósito de describir, explicar o interpretar un fenómeno de interés a partir del conocimiento existente (Comellas et al., 2023). Este diseño es el más apropiado para los propósitos del presente trabajo, ya que permite sistematizar el estado del arte sobre la aplicación de IA al diagnóstico radiológico de la EPOC sin la posibilidad, ni la necesidad de acceso directo a datos de pacientes.

El enfoque cualitativo se justifica por el carácter interpretativo y analítico del proceso de revisión: más allá de la cuantificación de métricas de desempeño de los modelos, el trabajo busca comprender el significado clínico de los hallazgos, identificar tendencias y brechas en la literatura, y construir un argumento coherente sobre las implicaciones para la práctica del tecnólogo en radiología en el contexto colombiano (Centner et al., 2023).

### Estrategia de Búsqueda Bibliográfica

La búsqueda bibliográfica se realizó en las siguientes bases de datos de acceso abierto y especializado:

***PubMed/MEDLINE:*** Principal base de datos de literatura biomédica, con acceso a artículos de más de 30.000 revistas indexadas.

***SciELO (Scientific Electronic Library Online):*** Repositorio latinoamericano de revistas científicas de acceso abierto, con énfasis en publicaciones en español y portugués.

**ScienceDirect (Elsevier):** Base de datos de ciencias de la salud con acceso a artículos de revistas Elsevier, muchos disponibles en acceso abierto.

**Cochrane Library:** Base de datos de revisiones sistemáticas y ensayos clínicos, referente metodológico en síntesis de evidencia.

**Google Scholar:** Motor de búsqueda académica con amplia cobertura de literatura gris e interdisciplinaria.

### **Descriptores y Operadores Booleanos**

Los descriptores utilizados combinan términos en español e inglés, de acuerdo con la nomenclatura internacional de la U.S. National Library of Medicine (Liu & Shen, 2024):

**En inglés:** - “Chronic obstructive pulmonary disease” AND “artificial intelligence” - “COPD” AND “deep learning” AND “chest X-ray” - “COPD” AND “convolutional neural network” AND “radiography” - “COPD” AND “machine learning” AND “diagnosis” - “COPD” AND “computed tomography” AND “artificial intelligence” - “Pulmonary emphysema” AND “neural network” AND “detection”

**En español:** - “Enfermedad pulmonar obstructiva crónica” AND “inteligencia artificial” - “EPOC” AND “aprendizaje profundo” AND “radiografía de tórax” - “EPOC” AND “redes neuronales convolucionales” - “Diagnóstico radiológico” AND “inteligencia artificial” AND “EPOC”

### **Criterios de Inclusión y Exclusión**

#### ***Criterios de Inclusión***

Artículos publicados entre 2016 y 2026

Acceso abierto (open access) o texto completo disponible

Idioma español o inglés.

Artículos originales, revisiones sistemáticas, metaanálisis, revisiones narrativas y guías de práctica clínica.

Relacionados con la EPOC y/o la aplicación de IA en diagnóstico radiológico pulmonar.

### ***Criterios de Exclusión***

Artículos duplicados en diferentes bases de datos.

Artículos sin texto completo disponible.

Publicaciones anteriores a 2016.

Estudios de caso único sin análisis cuantitativo del rendimiento del sistema.

Artículos no relacionados con el diagnóstico de la EPOC o con la aplicación de IA en imagen médica.

### **Proceso de Selección de Literatura**

El proceso de selección se realizó en cuatro fases a saber:

#### ***Fase 1 - Identificación***

Se realizaron las búsquedas con los descriptores mencionados en todas las bases de datos, obteniendo un total inicial de 50 referencias.

#### ***Fase 2 - Cribado por Título y Resumen***

Se excluyeron 10 referencias por no cumplir con los criterios de inclusión según título y resumen, quedando 40 referencias para revisión de texto completo.

#### ***Fase 3 - Evaluación de Texto Completo***

Se revisaron los artículos en su totalidad, excluyendo 10 por: acceso restringido (n=4), estudios no relacionados con el diagnóstico de EPOC (n=3), estudios sin métricas de desempeño reportadas (n=2), y calidad metodológica insuficiente (n=1).

***Fase 4 - Inclusión Final***

Quedaron 30 referencias elegibles, las cuales se seleccionaron para la elaboración de la presente revisión, priorizando los estudios con mayor relevancia para los objetivos específicos del trabajo, mayor calidad metodológica y mayor representatividad del estado del arte.

## Resultados

### Hallazgos sobre la EPOC en Radiografía Convencional y el Papel de la IA

La revisión de la literatura evidencia que la radiografía de tórax convencional, aunque limitada en sensibilidad para la detección de estadios leves de EPOC, constituye el campo de aplicación de IA con mayor potencial de impacto en contextos de recursos limitados, dado que representa la modalidad de imagen más accesible en los sistemas de salud de los países de renta baja y media (Centner et al., 2023; Yang et al., 2024).

### Comparación de Modelos de IA

La siguiente tabla presenta los estudios más relevantes identificados en la revisión, organizados por modalidad de imagen, modelo de IA utilizado, métricas de desempeño principales y país de procedencia de los datos (Yang et al., 2024; Lin et al., 2025; Chen et al., 2024; Heussel et al., 2023; Djellal et al., 2024; Dardouri, 2025; Raza et al., 2025; Rehman et al., 2023; Jadhav & Shingne, 2026)

**Tabla 1**

*Comparación de Modelos de IA*

Autor/Año	Modalidad	Modelo de IA	Métricas principales	País
Yang et al. (2024)	Radiografía + datos clínicos	CNN + parámetros clínicos (ResNet backbone)	AUC: 0,90; Sen: 82%; Esp: 87%	China
Lin et al. (2025)	TC cuantitativa (inspiración)	AutoCOPD (ML ensemble multicéntrico)	AUC: 0,94; Sen: 89%; Esp: 91%	China (11 centros)

Chen et al. (2024)	TC de alta resolución	U-Net + clasificador CNN	AUC: 0,92; correlación FEV1: 0,76	China/EE. UU.
Liu & Shen (2024)	Multimodal (TC + espirometría + clínica)	XGBoost + Random Forest + CNN	AUC: 0,91; Sen: 85%; Esp: 88%	China
Djellal et al. (2024)	Datos clínicos + función pulmonar	XGBoost, RF, SVM, MLP (comparativa)	AUC: 0,88 (XGBoost); F1: 0,85	Argelia/EE. UU.
Heussel et al. (2023)	TC (anomaly detection)	Red neuronal profunda (DenseNet)	Pearson r=0,76 vs FEV1%; AUC: 0,87	Alemania
Dardouri (2025)	Radiografía de tórax	CNN profunda (EfficientNetB4)	AUC: 0,88; Sen: 79%; Esp: 84%	Túnez/internacional
Raza et al. (2025)	Radiografía de tórax	Transfer learning (VGG, DenseNet, EfficientNet)	AUC: 0,91 (DenseNet-121); Acc: 89%	Pakistán/internacional
Rehman et al. (2023)	Radiografía de tórax (XAI)	DenseNet-121 + Grad-CAM	AUC: 0,85; F1: 0,83	Emiratos/Canadá
Jadhav & Shingne (2026)	Multimodal (imagen + espirometría)	Framework multimodal IA	Acc: 94%; Sen: 91%; Esp: 92%	India

*Nota.* Elaboración propia Sen = sensibilidad; Esp = especificidad; AUC = área bajo la curva

ROC; Acc = exactitud global; RF = Random Forest; MLP = Multilayer Perceptron; SVM =

Support Vector Machine.

### Limitaciones Identificadas en la Literatura

El análisis crítico de los estudios incluidos permite identificar las siguientes limitaciones recurrentes:

### ***Limitaciones Metodológicas***

La mayoría de los estudios utilizan diseños retrospectivos con datos de un único centro o de un número limitado de centros, lo que reduce la validez externa de los resultados.

La heterogeneidad en los criterios de diagnóstico de EPOC utilizados para generar las etiquetas de entrenamiento (criterio GOLD vs. criterio clínico vs. diagnóstico de alta hospitalaria) introduce variabilidad sistemática en la evaluación del rendimiento.

La validación de los modelos se realiza frecuentemente sobre subconjuntos de este dataset de entrenamiento, lo que sobreestima el rendimiento real en condiciones de despliegue clínico real.

### ***Limitaciones de Representatividad***

Ausencia casi total de estudios con datos latinoamericanos o colombianos en el campo de la IA aplicada al diagnóstico de EPOC por imagen.

Subrepresentación de la EPOC por biomasa y de fenotipos femeninos de EPOC en los datasets de entrenamiento.

Limitada representación de pacientes en estadios leves (GOLD I), que son precisamente el objetivo prioritario del diagnóstico temprano.

### ***Limitaciones Técnicas***

La mayoría de los modelos reportados no están disponibles en código abierto ni en plataformas de despliegue clínico, lo que dificulta su validación independiente y su comparación directa.

Los métodos de XAI disponibles (Grad-CAM, LIME) proporcionan explicaciones locales y no garantizan la interpretabilidad global del modelo.

La integración de los modelos en los sistemas PACS/RIS existentes presenta desafíos técnicos de interoperabilidad que raramente son abordados en las publicaciones de validación.

## Conclusiones

La revisión documental confirma que la radiografía de tórax, aunque limitada en sensibilidad para la detección de estadios tempranos de la EPOC, exhibe un conjunto bien caracterizado de hallazgos hiperinflación, aplanamiento diafragmático, hiperclaridad pulmonar, engrosamiento bronquial, que constituyen los biomarcadores imagenológicos primarios sobre los que se entrenan y evalúan los modelos de IA (Pompe & Mohamed Hoesein, 2021; Cahn et al., 2020). La calidad técnica de las imágenes, adecuada inspiración, correcta penetración, ausencia de rotación, es un determinante crítico de la confiabilidad de los sistemas de IA, lo que subraya el rol insustituible del tecnólogo en radiología en la garantía de calidad del proceso diagnóstico (Bushberg et al., 2020; Machacado-Rojas & Aparicio-Pico, 2021).

La TC de alta resolución permanece como la modalidad gold standard para la cuantificación del enfisema y la estadificación imagenológica de la EPOC, con capacidad para detectar alteraciones estructurales que la radiografía convencional no puede visualizar (Tanabe & Hirai, 2021; Chen et al., 2024). Sin embargo, su limitada accesibilidad en contextos de recursos restringidos posiciona a la radiografía de tórax con soporte de IA como la herramienta más realista para el diagnóstico ampliado de la EPOC en entornos de atención primaria en Colombia y América Latina (Centner et al., 2023; Gil Rojas et al., 2019).

Los modelos de aprendizaje profundo, especialmente las CNN con arquitecturas ResNet, DenseNet y EfficientNet con transfer learning, han demostrado rendimiento diagnóstico notable en la clasificación de la EPOC a partir de radiografías de tórax y TC, con valores de AUC consistentemente superiores a 0,85 en los estudios de mayor calidad metodológica. Los modelos multimodales que integran imagen con datos clínicos y funcionales superan a los modelos unimodales, alcanzando AUC de hasta 0,94. Los modelos multicéntricos, como AutoCOPD (Lin

et al., 2025), representan un avance metodológico significativo hacia la generalización clínica de estos sistemas.

Sin embargo, la comparación directa entre estudios es limitada por la heterogeneidad de los datasets, los criterios diagnósticos de referencia y las métricas reportadas (Liu & Shen, 2024; Mehrabi et al., 2021). La ausencia de estudios de validación con datos latinoamericanos es la brecha de investigación más urgente desde la perspectiva colombiana (Centner et al., 2023; Comellas et al., 2023).

Las limitaciones más críticas de los sistemas de IA aplicados al diagnóstico radiológico de la EPOC son: la falta de representatividad de los datos de entrenamiento respecto a las poblaciones de América Latina (Mehrabi et al., 2021; Centner et al., 2023); la opacidad de los modelos y la limitada capacidad de los métodos de XAI actuales para generar explicaciones clínicamente satisfactorias (Rehman et al., 2023; Fernández-Villar et al., 2020); y la ausencia de marcos regulatorios claros en Colombia para la aprobación, supervisión y auditoría de sistemas de IA médica (Albisua & Pacheco, 2024; Lippi & Plebani, 2025).

Los algoritmos de inteligencia artificial aplicados a la radiografía de tórax contribuyen al diagnóstico temprano de la EPOC mediante la detección automatizada y cuantitativa de los hallazgos radiológicos característicos de la enfermedad como hiperinflación pulmonar, aplanamiento diafragmático, hiperclaridad, con un rendimiento diagnóstico que supera a la interpretación visual no asistida, especialmente en estadios intermedios (Yang et al., 2024; Guo et al., 2024). No obstante, esta contribución es actualmente potencial más que real en el contexto latinoamericano, dado que los modelos disponibles han sido desarrollados y validados en poblaciones que no representan adecuadamente la diversidad étnica, demográfica y etiológica de la EPOC en Colombia (Centner et al., 2023; Mehrabi et al., 2021).

Las proyecciones de la IA en el diagnóstico de EPOC en Colombia son prometedoras, pero requieren condiciones habilitadoras que aún no están completamente establecidas (Mayer, 2023). A mediano plazo, la integración de modelos de IA en los sistemas de información radiológica de las instituciones de salud colombianas podría mejorar significativamente la tasa de detección de EPOC en estadios tempranos, siempre que esté acompañada de formación del personal, validación local rigurosa y marcos regulatorios apropiados (Albisua & Pacheco, 2024; Lippi & Plebani, 2025). A largo plazo, la construcción de bases de datos colombianas y latinoamericanas de imagen pulmonar anotada permitirá el desarrollo de modelos adaptados a las características propias de la EPOC en la región, incluyendo el fenotipo por biomasa (Centner et al., 2023; Comellas et al., 2023).

El tecnólogo en radiología, formado para comprender y auditar estos sistemas, tiene un papel central en esta transición tecnológica (Machacado-Rojas & Aparicio-Pico, 2021; Kornafeld et al., 2025). Su posición privilegiada en el flujo de trabajo de la imagen médica lo convierte no solo en usuario sino en garante de la calidad y la equidad del diagnóstico radiológico asistido por IA (Fernández-Villar et al., 2020).

### Referencias Bibliográficas

- Aseri, M. (2025). The role of artificial intelligence and machine learning in asthma and chronic obstructive pulmonary disease management. *Learning Gate*, 9(2).  
<https://doi.org/10.55214/25768484.v9i2.5088>
- Avila-Tomás, J. F., Mayer-Pujadas, M. A., & Quesada-Varela, V. J. (2020a). La inteligencia artificial y sus aplicaciones en medicina I: Introducción antecedentes a la IA y robótica. *Atención Primaria*, 52(10), 778–784. <https://doi.org/10.1016/j.aprim.2020.04.013>
- Avila-Tomás, J. F., Mayer-Pujadas, M. A., & Quesada-Varela, V. J. (2020b). La inteligencia artificial y sus aplicaciones en medicina II: Importancia actual y aplicaciones prácticas. *Atención Primaria*, 53(1), 81–88. <https://doi.org/10.1016/j.aprim.2020.04.014>
- Albisua, J., & Pacheco, P. (2024). Límites éticos en el uso de la inteligencia artificial (IA) en medicina. *Open Respiratory Archives*, 7(1), 100383.  
<https://doi.org/10.1016/j.opresp.2024.100383>
- Bastidas, A., Granados, C., Zambrano, C., Tavera, D., Parra-Cárdenas, D., Tuta-Quintero, E., ... & Martínez, Á. (2024). Factores relacionados con la mortalidad en pacientes con enfermedad pulmonar obstructiva crónica en población colombiana. *Biomédica*, 44.  
<https://doi.org/10.7705/biomedica.7140>
- Boers, E., Barrett, M., Su, J. G., Benjafield, A. V., Sinha, S., Kaye, L., Zar, H. J., Vuong, V., Tellez, D., Gondalia, R., Rice, M. B., Nunez, C. M., Wedzicha, J. A., & Malhotra, A. (2023). Global burden of chronic obstructive pulmonary disease through 2050. *JAMA Network Open*, 6(12), e2346598. <https://doi.org/10.1001/jamanetworkopen.2023.46598>
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2020). *The essential physics of medical imaging* (3rd ed.). Lippincott Williams & Wilkins.

- Cahn, A., Young, A., Rangelov, B., Hawkes, D., Wilson, F. J., Hurst, J., Jacob, J., & Lee, S. (2020). Thoracic imaging at exacerbation of chronic obstructive pulmonary disease: A systematic review. *International Journal of COPD*, *15*, 1751–1763.  
<https://doi.org/10.2147/COPD.S250746>
- Centner, C. S., Robertson, N. M., & Siddharthan, T. (2023). Integrating artificial intelligence in the diagnosis of COPD globally: A way forward. *JCOPDF*, *10*(4).  
<https://doi.org/10.15326/jcopdf.2023.0449>
- Chen, R., Qi, S., Xia, S., Wu, Y., & Liang, Z. (2024). Artificial intelligence in COPD CT images: Identification, staging, and quantitation. *Respiratory Research*, *25*, 319.  
<https://doi.org/10.1186/s12931-024-02913-z>
- Comellas, A., Saha, P., & Nadeem, S. A. (2023). A survey on artificial intelligence in pulmonary imaging. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*.  
<https://doi.org/10.1002/widm.1510>
- Dardouri, S. (2025). A deep convolutional neural network model for lung disease detection using chest X-ray imaging. *Pulmonary Medicine*. <https://doi.org/10.1155/pm/6614016>
- Djellal, A., Sheta, A., Surani, S., Aljahdali, S., & Elashmawi, W. H. (2024). Machine learning for enhanced COPD diagnosis: A comparative analysis of classification algorithms. *Diagnostics*, *14*(24), 2822. <https://doi.org/10.3390/diagnostics14242822>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, *25*(1), 24–29.  
<https://doi.org/10.1038/s41591-018-0316-z>

- Estrada-Álvarez, J. M., Orozco-Hernández, J., & Aristizabal-Franco, L. E. (2020). Validación del puntaje de valoración de la gravedad de la EPOC en población colombiana. *Biomédica*, *40*. <https://doi.org/10.7705/biomedica.5123>
- Fernández-Villar, A., Ruano-Raviña, A., & Corbacho Abelaira, M. C. (2020). Inteligencia artificial en radiología torácica. ¿Un reto en tiempos de la COVID-19? *Archivos de Bronconeumología*, *57*, 15–16. <https://doi.org/10.1016/j.arbres.2020.10.008>
- Gil Rojas, Y., Torres Duque, C. A., Figueredo, M., Hernandez, F., Castañeda Cardona, C., Lasalvia, P., & Rosselli, D. (2019). Estimación de la prevalencia de EPOC en Colombia a partir del Registro Individual de Prestaciones de Servicios de Salud (RIPS). *Revista Colombiana de Neumología*, *31*(1). <https://doi.org/10.30789/RCNEUMOLOGIA.V31.N1.2019.325>
- Global Initiative for Chronic Obstructive Lung Disease (GOLD). (2024). *Global strategy for diagnosis, management, and prevention of COPD*. <https://goldcopd.org/2024-gold-report/>
- Guo, L., Zhou, C., Xu, J., Huang, C., Yu, Y., & Lu, G. (2024). Deep learning for chest X-ray diagnosis: Competition between radiologists with or without artificial intelligence assistance. *Journal of Digital Imaging*, *37*, 741–752. <https://doi.org/10.1007/s10278-024-00990-6>
- Heussel, C. P., Lüth, C. T., Kauczor, H., Biederer, J., Maier-Hein, K., Nolden, M., ... & Norajitra, T. (2023). Prediction of disease severity in COPD: A deep learning approach for anomaly-based quantitative assessment of chest CT. *European Radiology*, *34*, 3846–3856. <https://doi.org/10.1007/s00330-023-10540-3>

- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, *18*(8), 500–510.  
<https://doi.org/10.1038/s41568-018-0016-5>
- Jadhav, R. S., & Shingne, H. (2026). An AI-driven multimodal framework for detection and severity assessment of chronic bronchitis (CB) and chronic obstructive pulmonary disease (COPD). *International Journal of Drug Delivery Technology*.  
<https://doi.org/10.25258/ijddt.16.41s.37>
- Johnson, A. E. W., Pollard, T. J., Berkowitz, S. J., Greenbaum, N. R., Lungren, M. P., Deng, C. Y., ... & Horng, S. (2019). MIMIC-CXR: A large publicly available database of labeled chest radiographs. *Scientific Data*, *6*, 317. <https://doi.org/10.1038/s41597-019-0322-0>
- Kornafeld, A., Little, G., & Frye, L. (2025). The role of artificial intelligence in interventional pulmonology. *Journal of Bronchology & Interventional Pulmonology*.  
<https://doi.org/10.1097/LBR.0000000000001051>
- Kurniawan, Y., Susilo, B., & Rahman, S. (2025). Revolutionizing COPD and asthma management with artificial intelligence. *medRxiv*.  
<https://doi.org/10.1101/2025.03.18.25324219>
- Lin, F., Zhang, Z., Wang, J., Liang, C., Xu, J., Zeng, X., Zeng, Q., Chen, H., Zhuang, J., Ma, Y., Ma, Q. L., Shi, R., Xu, J., Li, Y., Yuan, L., Wei, X., Wu, L., Huang, R., Xiao, T., Liang, W., He, J., Liu, Y., Liang, Z., Zhong, N., & Lu, W. (2025). AutoCOPD—A novel and practical machine learning model for COPD detection using whole-lung inspiratory quantitative CT measurements: A retrospective, multicenter study. *EClinicalMedicine*, *82*, 103166. <https://doi.org/10.1016/j.eclinm.2025.103166>

- Lippi, G., & Plebani, M. (2025). Luces y sombras de la inteligencia artificial en la medicina de laboratorio. *Advances in Laboratory Medicine*, 6(1), 4–6. <https://doi.org/10.1515/almed-2025-0039>
- Liu, H., & Shen, X. (2024). Using machine learning for early detection of chronic obstructive pulmonary disease: A narrative review. *Respiratory Research*, 25, 345. <https://doi.org/10.1186/s12931-024-02960-6>
- Machacado-Rojas, A. M., & Aparicio-Pico, L. E. (2021). Técnicas de inteligencia artificial aplicadas al análisis de imágenes diagnóstico. *Eco Matemático*, 12(2). <https://doi.org/10.22463/17948231.3237>
- Mayer, M. A. (2023). Inteligencia artificial en atención primaria: un escenario de oportunidades y desafíos. *Atención Primaria*, 55(11), 102744. <https://doi.org/10.1016/j.aprim.2023.102744>
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 1–35. <https://doi.org/10.1145/3457607>
- Montserrat-Capdevila, J., Gea-Sánchez, M., Olivares-Sanzo, P., & Vaqué Castilla, P. (2025). Incidencia, comorbilidad asociada y factores de riesgo de agudización grave de la EPOC: estudio de cohorte retrospectivo 2021-2022. *Atención Primaria*, 57(10), 103259. <https://doi.org/10.1016/j.aprim.2025.103259>
- Organización Mundial de la Salud (OMS). (2024). *Enfermedad pulmonar obstructiva crónica (EPOC)*. [https://www.who.int/es/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-\(copd\)](https://www.who.int/es/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-(copd))

- Pompe, E., & Mohamed Hoesein, F. M. (2021). Role of visual assessment of chronic obstructive pulmonary disease on chest CT. *Journal of Thoracic Disease, 13*.  
<https://doi.org/10.21037/jtd-21-1527>
- Raza, A., Ahmad, A., Tauseef, H., Momynzhanova, K., Shamas, M., Mamyrbayev, O. J., Alahmadi, T. J., & Ghadi, Y. (2025). Classification of pulmonary diseases from chest radiographs using deep transfer learning. *PLOS ONE*.  
<https://doi.org/10.1371/journal.pone.0316929>
- Rehman, A., Nobanee, H., Khan, M. U. G., Bahaj, S. A. O., Saba, T., & Naz, Z. (2023). An explainable AI-enabled framework for interpreting pulmonary diseases from chest radiographs. *Cancers, 15*(1), 314. <https://doi.org/10.3390/cancers15010314>
- Tanabe, N., & Hirai, T. (2021). Recent advances in airway imaging using micro-computed tomography and computed tomography for chronic obstructive pulmonary disease. *Korean Journal of Internal Medicine, 36*(6), 1294–1308.  
<https://doi.org/10.3904/kjim.2021.124>
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-ray8: Hospital-scale chest X-ray database and benchmarks. *Proceedings of the CVPR*.  
<https://doi.org/10.1109/CVPR.2017.369>
- Willer, K., Fingerle, A., Noichl, W., De Marco, F., Frank, M., Urban, T., ... & Pfeiffer, F. (2021). X-ray dark-field chest imaging can detect and quantify emphysema in COPD patients. *medRxiv*. <https://doi.org/10.1101/2021.01.15.21249798>
- Yang, H., Han, L., Zhang, L., Zou, M., Gong, M., Meng, P., Zhang, T., Ding, W., Zou, X., & Ren, Y. (2024). Screening and staging of chronic obstructive pulmonary disease with

Deep learning based on chest X-ray images and clinical parameters. *BMC Pulmonary Medicine*, 24, 153. <https://doi.org/10.1186/s12890-024-02945-7>