

Sesgos algorítmicos en inteligencia artificial y variabilidad anatómica en radiografía de tórax: una revisión documental

Erika Tatiana Pedraza Vargas

Jairbeth Alejandra León Pardo

Asesor

Edna Rocio Jamaica Guio

Universidad Nacional Abierta a Distancia

Escuela de Ciencias de la Salud-ECISA

Tecnología en Radiología e Imágenes Diagnósticas.

2026

Dedicatoria

Dedicamos este trabajo, en primer lugar, nuestras familias, quienes han sido el pilar fundamental a lo largo de nuestro proceso académico. Su apoyo incondicional, paciencia y confianza en nuestras capacidades han sido determinantes para continuar incluso en los momentos de mayor dificultad. Cada logro alcanzado es también reflejo de su amor, esfuerzo y acompañamiento constante.

A todas aquellas personas que, de una u otra forma, han contribuido a nuestro crecimiento personal y profesional, brindándonos palabras de aliento, orientación y motivación en este camino. Su presencia ha sido clave para fortalecer nuestro compromiso con la formación académica y la superación personal.

Finalmente, dedicamos este trabajo a nosotras mismas, por la constancia, disciplina y resiliencia demostradas a lo largo de este proceso. Por asumir los retos con responsabilidad y por mantener la determinación de culminar esta etapa con compromiso y excelencia.

Agradecimientos

Expresamos nuestro más sincero agradecimiento a la Universidad Nacional Abierta y a Distancia por brindarnos la oportunidad de formarnos profesionalmente en un entorno académico que promueve la autonomía, el pensamiento crítico y el aprendizaje significativo.

A los docentes que hicieron parte de este proceso, por su orientación, acompañamiento y aportes académicos, los cuales fueron fundamentales para el desarrollo de este trabajo. Su compromiso con la formación de profesionales íntegros dejó una huella significativa en nuestro proceso de aprendizaje.

A las fuentes bibliográficas y a los autores consultados, cuyo trabajo investigativo permitió sustentar teóricamente esta investigación y enriquecer el análisis realizado.

De manera especial, agradecemos a nuestra familia por su apoyo constante, comprensión y motivación, elementos esenciales para la culminación de este proceso académico. Su respaldo ha sido un motor fundamental en cada etapa de este camino.

Finalmente, agradecemos a todas las personas que, directa o indirectamente, contribuyeron al desarrollo de este trabajo, aportando desde su conocimiento, experiencia o apoyo emocional.

Resumen

La radiografía de tórax es una herramienta fundamental en el diagnóstico clínico debido a su accesibilidad y utilidad en la evaluación de patologías pulmonares y cardiovasculares. Su calidad depende de factores técnicos y de las características anatómicas del paciente, las cuales pueden variar entre diferentes grupos poblacionales.

El presente estudio tuvo como objetivo analizar la relación entre la variabilidad anatómica según grupos étnicos y los posibles sesgos en algoritmos de inteligencia artificial aplicados a la interpretación de radiografías de tórax. Se empleó un enfoque cualitativo, de tipo documental y diseño descriptivo-analítico, basado en la revisión de literatura científica.

Los resultados evidencian que las diferencias antropométricas influyen en la formación de la imagen radiográfica y pueden afectar el desempeño de los sistemas de inteligencia artificial. Asimismo, se identificó que la falta de representatividad de ciertos grupos poblacionales en los conjuntos de datos contribuye a la aparición de sesgos algorítmicos, lo que impacta la precisión diagnóstica.

Se concluye que es necesario promover la inclusión de poblaciones diversas en las bases de datos médicas y desarrollar modelos de inteligencia artificial más equitativos, con el fin de mejorar la calidad del diagnóstico y garantizar la equidad en salud.

Palabras clave: Radiografía de Tórax, Inteligencia Artificial, Sesgos Algorítmicos, Variabilidad Antropométrica, Equidad en Salud.

Abstract

Chest radiography is a fundamental diagnostic tool widely used in clinical practice due to its accessibility and effectiveness in evaluating pulmonary and cardiovascular conditions.

However, image quality and interpretation are influenced by technical factors and anatomical variability among different population groups.

This study aimed to analyze the relationship between anatomical variability across ethnic groups and potential biases in artificial intelligence algorithms applied to chest radiograph interpretation. A qualitative, documentary approach with a descriptive-analytical design was employed, based on a review of scientific literature.

The results show that anthropometric differences can affect image formation and influence the performance of artificial intelligence systems. Furthermore, the lack of representation of certain population groups in medical datasets contributes to algorithmic bias, impacting diagnostic accuracy.

It is concluded that promoting diversity in medical datasets and developing more inclusive artificial intelligence models are essential to improve diagnostic accuracy and ensure equity in healthcare.

Keywords: Chest Radiography, Artificial Intelligence, Algorithmic Bias, Anthropometric Variability, Health Equity.

Contenido

Introducción	10
Planteamiento del Problema	12
Justificación	14
Objetivos.....	16
Objetivo General.....	16
Objetivos Específicos.....	16
Marco Teórico	17
Fundamentos de la Radiografía de Tórax y Calidad de Imagen.....	18
<i>Principios de Formación de la Imagen</i>	18
<i>Factores Técnicos: kVp y mAs</i>	19
<i>Interacciones Físicas y Criterios de Calidad Diagnóstica</i>	21
Variabilidad Antropométrica y su Impacto en la Radiografía.....	23
Variabilidad Anatómica y Antropométrica Según la Etnia	23
<i>Densidad Mineral Ósea (DMO),</i>	24
<i>Composición del Tejido Blando</i>	25
<i>Estratificación Encubierta</i>	26
Bases de Datos Utilizadas en Inteligencia Artificial Radiológica	27
Limitaciones de las Bases de Datos Utilizadas.....	27
Sesgo de Datos (Data Bias).....	28
Precisión Diagnóstica Diferencial.....	29
Representatividad en la Literatura Médica y Bases de Datos.....	30
Integración Crítica y Aportes Investigativos.....	31

Impacto en el Contexto Colombiano	32
Marco Metodológico.....	34
Fase 1: Proceso de Búsqueda de la Información	34
Fase 2: Análisis de los Artículos	34
Fase 3: Análisis de la Información.....	34
<i>Criterios de Inclusión</i>	34
<i>Criterios de Exclusión</i>	35
<i>Diagrama de Flujo</i>	35
Análisis de Resultados	36
Objetivo 1: Principios Técnicos de la Radiografía Torácica y su Conexión con la Variabilidad Anatómica.....	36
Objetivo 2: Variaciones Anatómicas y Antropométricas entre Diversos Grupos de Población.....	36
Objetivo 3: Prejuicios en Algoritmos de Inteligencia Artificial y su Efecto en el Diagnóstico.	37
Conclusiones.....	41
Referencias.....	43

Lista de Figuras

Figura 1 <i>Principios Formación de la Imagen</i>	19
Figura 2 <i>Factores Técnicos de la Imagen</i>	20
Figura 3 <i>Radiografía de Tórax con Penetración Adecuada</i>	22
Figura 4 <i>Radiografía Sub-penetrada que Afecta el Contraste Estructural</i>	22
Figura 5 <i>Densidad Mineral Ósea (DMO)</i>	25
Figura 6 <i>Enfermedades Pulmonares</i>	26
Figura 7 <i>Variabilidad Anatómica Torácica</i>	26
Figura 8 <i>Inteligencia Artificial en Radiología</i>	29
Figura 9 <i>Análisis de Sesgo</i>	29
Figura 10 <i>Sesgos en Algoritmos de Diagnóstico y Equidad en Salud</i>	30
Figura 11 <i>Impacto de la Inteligencia Artificial en la Equidad en Salud</i>	30
Figura 12 <i>Porcentaje Demográfico</i>	31

Lista de Tablas

Tabla 1 <i>Comparación de Enfoques sobre Sesgos en Inteligencia Artificial en Radiología.</i>	38
Tabla 2 <i>Relación entre Factores Técnicos, Variabilidad Anatómica e Implicaciones en Inteligencia Artificial</i>	39

Introducción

En la actualidad, la radiografía de tórax continúa siendo una de las herramientas diagnósticas más utilizadas en la práctica clínica, debido a su accesibilidad, bajo costo y utilidad en la evaluación de patologías pulmonares y cardiovasculares. No obstante, la calidad e interpretación de estas imágenes no dependen únicamente de factores técnicos, sino también de las características anatómicas del paciente, las cuales pueden variar significativamente entre diferentes grupos poblacionales (Bushberg et al., 2012).

En paralelo, el avance de la inteligencia artificial ha permitido el desarrollo de algoritmos capaces de asistir en la interpretación de imágenes médicas, mejorando potencialmente la eficiencia y precisión diagnóstica. Sin embargo, diversos estudios han evidenciado que estos sistemas pueden presentar sesgos cuando son entrenados con datos que no representan adecuadamente la diversidad poblacional, lo que puede afectar su desempeño en contextos clínicos reales (Obermeyer et al., 2019; Norori et al., 2021).

A partir de la revisión documental, se ha identificado que existe tanto consenso como discrepancias entre los autores respecto al origen y las implicaciones de estos sesgos. Mientras algunos enfoques se centran en aspectos técnicos relacionados con el entrenamiento de los modelos, otros destacan la influencia de determinantes sociales en la generación de desigualdades en salud.

En este contexto, el presente trabajo tiene como propósito analizar la relación entre la variabilidad anatómica y los sesgos en algoritmos de inteligencia artificial aplicados a radiología, a partir de la comparación crítica de la literatura científica. De esta manera, se busca comprender no solo las limitaciones actuales de estos sistemas, sino también las posibles estrategias para

mejorar su desempeño y contribuir a una atención en salud más equitativa, especialmente en contextos diversos como el colombiano.

Planteamiento del Problema

La inteligencia artificial (IA) se ha incorporado de manera gradual en el ámbito de la radiología como un recurso auxiliar para la interpretación de imágenes diagnósticas, sobre todo en radiografía torácica. Los progresos en aprendizaje profundo han facilitado la creación de algoritmos que pueden identificar patologías con precisiones similares a las de expertos, lo que constituye una oportunidad significativa para reforzar el diagnóstico temprano, optimizar tiempos y mejorar la atención sanitaria (Esteva et al., 2019).

No obstante, la efectividad de estos sistemas se relaciona directamente con los datos utilizados para su entrenamiento. La IA identifica patrones a partir de bases de datos actuales, por lo que su desempeño puede verse influenciado cuando esos datos tienen desbalances o carecen de representatividad. Según Mehrabi et al. (2021), los sesgos en los algoritmos frecuentemente surgen cuando los conjuntos de datos de entrenamiento no representan de manera adecuada la diversidad de la población real, lo que produce resultados desiguales entre diferentes grupos.

En el sector de la salud, esta cuestión cobra una importancia crucial ya que los fallos impactan no solo en indicadores técnicos, sino también en decisiones médicas. Obermeyer et al. (2019) mostraron que un algoritmo destinado a manejar necesidades médicas subestimaba la atención necesaria para pacientes afroamericanos, destacando cómo estos sistemas pueden perpetuar desigualdades estructurales. De forma similar, Buolamwini y Gebru (2018) encontraron tasas de error considerablemente mayores en individuos con tonos de piel oscuros, evidenciando que la escasez de diversidad afecta el rendimiento de la tecnología.

En la radiografía de tórax, la escasa representación de grupos étnicos minoritarios en los conjuntos de datos de formación puede resultar en una menor precisión diagnóstica para estas

poblaciones, elevando los falsos negativos o los diagnósticos tardíos. Esto representa un desafío no solo técnico, sino también ético, dado que una herramienta diagnóstica con rendimiento inconsistente pone en riesgo el principio de equidad en salud. En Colombia, el tema ha sido tratado por entidades académicas y científicas que alertan sobre el peligro de la discriminación racial en la creación y uso de IA (Academia Nacional de Medicina de Colombia, 2024; UNAD, 2025). Incluso medios de comunicación han informado sobre fallas y errores relacionados con el uso de IA en cuestiones médicas, lo que demuestra la necesidad de una evaluación crítica antes de su implementación clínica (Pulzo, 2025).

Por lo tanto, el problema principal se centra en entender de qué manera la ausencia de representatividad étnica en conjuntos de datos de entrenamiento influye en la precisión diagnóstica de algoritmos utilizados para radiografías de tórax, así como sus repercusiones clínicas en términos de equidad, seguridad del paciente y justicia en salud. Para organizar de manera adecuada este análisis, se utilizan enfoques metodológicos de investigación que facilitan la delimitación del problema y el examen de sus causas y efectos, como el árbol de problemas (González et al., 2023; Ortiz, 2022).

Justificación

La investigación sobre los sesgos algorítmicos en inteligencia artificial aplicada a imágenes diagnósticas es pertinente en cuatro aspectos: científico, clínico, social y metodológico.

Desde una óptica científica y tecnológica, examinar la conexión entre la representatividad étnica y la exactitud diagnóstica facilita entender de qué manera los modelos de IA se generalizan a poblaciones variadas. La literatura señala que los sesgos en el aprendizaje automático a menudo surgen de desequilibrios en los conjuntos de datos, impactando la validez y la fiabilidad de los sistemas (Mehrabi et al., 2021). Como resultado, este análisis ayuda a la creación de algoritmos más sólidos y justos.

En segundo lugar, desde la perspectiva clínica, el sesgo algorítmico puede afectar de manera directa la seguridad del paciente. Si un algoritmo muestra menor sensibilidad hacia ciertos grupos étnicos, incrementará la probabilidad de falsos negativos, lo que conlleva diagnósticos tardíos, demoras en tratamientos y posibles complicaciones. Esto tiene particular relevancia en la radiografía de tórax, debido a su uso común en enfermedades respiratorias de alta incidencia.

En tercer lugar, bajo una óptica ética y social, la aplicación de IA con resultados desiguales puede agravar las inequidades históricas en cuanto al acceso y la calidad de atención sanitaria. Si un instrumento de diagnóstico tiene un rendimiento superior en determinados grupos poblacionales e inferior en otros, se crea una desigualdad tecnológica que va en contra del principio de equidad en salud. Por lo tanto, se estima esencial incluir auditorías de equidad, validación en diferentes poblaciones y estrategias de reducción del sesgo antes de su aplicación clínica (Academia Nacional de Medicina de Colombia, 2024; UNAD, 2025).

Finalmente, esta labor se fundamenta en el enfoque metodológico, dado que refuerza

El proceso de investigación a través de la aplicación de herramientas de revisión bibliográfica y la organización del problema. Hernández et al. (2022) subrayan que una revisión bibliográfica exhaustiva es crucial en estudios clínicos, ya que proporciona un respaldo teórico al problema y asegura la calidad del análisis. De igual manera, los recursos didácticos creados en la UNAD guían la elaboración de un enfoque robusto, la generación de interrogantes de investigación y el análisis causal a través del diagrama de problemas (Corredor, 2018; Guerrero, 2024; Lancheros, 2023; Ortiz, 2022).

En resumen, este estudio es relevante ya que la incorporación de IA en radiología progresa aceleradamente, mientras que la validación ética y poblacional de estas tecnologías aún enfrenta desafíos. Examinar el sesgo causado por la escasez de diversidad étnica proporcionará pruebas clave para fomentar el uso responsable de la IA, asegurando seguridad, equidad y justicia en el ámbito de la salud.

Objetivos

Objetivo General

Analizar la relación entre la variabilidad anatómica según grupos étnicos y los sesgos en algoritmos de inteligencia artificial aplicados a la interpretación de radiografías de tórax, mediante una revisión documental.

Objetivos Específicos

Caracterizar los principios físicos y parámetros técnicos (kVp y mAs) que determinan la calidad de la imagen en la radiografía de tórax y su interacción con los tejidos biológicos

Sintetizar las variaciones anatómicas y antropométricas, como la densidad mineral ósea y el grosor de la pared torácica, presentes en diversos grupos étnicos y su impacto en la atenuación del haz de rayos X

Evaluar el impacto de la falta de representatividad poblacional en las bases de datos de entrenamiento sobre la precisión diagnóstica de los algoritmos de inteligencia artificial, identificando posibles riesgos de inequidad en salud

Marco Teórico

La radiografía de tórax constituye uno de los estudios de imagen más utilizados en la práctica clínica para la evaluación de patologías respiratorias, cardiovasculares y torácicas. Su utilidad diagnóstica se debe a su rapidez, bajo costo y capacidad para ofrecer una visión general de las estructuras pulmonares, mediastínicas y óseas. Sin embargo, la calidad diagnóstica de una radiografía no depende únicamente del equipo utilizado, sino también de factores físicos, técnicos y biológicos que influyen en la formación y la interpretación de la imagen.

En las últimas décadas, la inteligencia artificial (IA) ha comenzado a incorporarse en la interpretación de imágenes médicas, especialmente en radiología. Los modelos de aprendizaje profundo han demostrado un desempeño prometedor en la detección automatizada de patologías en radiografías de tórax, incluyendo neumonía, nódulos pulmonares y cardiomegalia. No obstante, el rendimiento de estos algoritmos depende directamente de la calidad y representatividad de los datos utilizados durante su entrenamiento.

En este contexto, es necesario comprender tres dimensiones fundamentales: los fundamentos físicos de la formación de la imagen radiográfica, la variabilidad anatómica entre diferentes poblaciones y el impacto de los sesgos presentes en los conjuntos de datos utilizados para entrenar modelos de inteligencia artificial. La interacción entre estos factores puede influir tanto en la calidad de la imagen como en la precisión diagnóstica de los sistemas automatizados.

Por lo tanto, este marco teórico analiza la relación entre los principios físicos de la radiografía de tórax, las diferencias antropométricas entre grupos poblacionales y los posibles sesgos presentes en los algoritmos de inteligencia artificial utilizados en radiología

Fundamentos de la Radiografía de Tórax y Calidad de Imagen

La radiografía convencional se basa en la atenuación diferencial del haz de rayos X al interactuar con tejidos de distinta composición. El efecto fotoeléctrico predomina en estructuras de mayor número atómico como el hueso, mientras que la dispersión Compton predomina en tejidos blandos y contribuye al ruido en la imagen (Bushberg et al., 2012).


Principios de Formación de la Imagen

En radiología diagnóstica, la formación de la imagen se basa en la interacción de los rayos X con los tejidos del cuerpo humano. Cuando el haz de radiación atraviesa el organismo, parte de la energía es absorbida y otra parte alcanza el detector, generando diferencias de atenuación que permiten representar las estructuras anatómicas (Bushberg et al., 2012). En el rango de energías utilizado en radiografía diagnóstica predominan principalmente dos fenómenos físicos: el efecto fotoeléctrico y la dispersión Compton. El efecto fotoeléctrico ocurre cuando un fotón de rayos X es completamente absorbido por un electrón de una capa interna del átomo, fenómeno que se presenta con mayor frecuencia en materiales con mayor número atómico, como el calcio presente en el tejido óseo (Bushberg et al., 2012).

Por otra parte, la dispersión Compton se produce cuando un fotón interactúa con un electrón de la capa externa del átomo, transfiriendo parte de su energía y cambiando su dirección. Este fenómeno es predominante en tejidos blandos y contribuye a la radiación dispersa, lo que puede reducir el contraste de la imagen radiográfica (Shepard et al., 2014).

Figura 1

Principios Formación de la Imagen.



Nota. Efecto fotoeléctrico y Compton de cómo se genera una imagen, Tomado de Orozco, (2020)

Factores Técnicos: kVp y mAs

En radiografía diagnóstica, los parámetros técnicos del equipo influyen directamente en la calidad de la imagen obtenida. Entre los factores más importantes se encuentran el kilovoltaje pico (kVp) y el miliamperaje por segundo (mAs), los cuales determinan las características físicas del haz de rayos X y su interacción con los tejidos del paciente. El kilovoltaje (kVp) define la energía de los fotones emitidos por el tubo de rayos X y, por lo tanto, su capacidad de penetración a través de las estructuras anatómicas. Un incremento en el kVp produce fotones con mayor energía, capaces de atravesar tejidos más densos, lo que se traduce en una mayor penetración del haz y una disminución del contraste radiográfico debido al aumento de la radiación dispersa (Bushberg et al., 2012; Shepard et al., 2014). Por otro lado, el miliamperaje-segundo (mAs) controla la cantidad total de fotones producidos durante la exposición. A diferencia del kVp, este parámetro no modifica la energía de los fotones, sino la intensidad del haz de radiación. Un aumento en el mAs incrementa la cantidad de radiación que alcanza el detector, lo que contribuye a reducir el ruido cuántico y mejorar la relación señal-ruido de la imagen radiográfica (Bushberg et al., 2012).

La adecuada selección de estos parámetros resulta fundamental para garantizar imágenes diagnósticas de calidad, evitando tanto la subexposición como la sobreexposición del paciente. En la práctica clínica, los técnicos en radiología deben ajustar los valores de kVp y mAs teniendo en cuenta las características anatómicas y la complejión del paciente, ya que factores como el grosor de la pared torácica, la densidad mineral ósea y la distribución del tejido adiposo pueden modificar el grado de atenuación del haz de rayos X (Shepard et al., 2014). En este sentido, las variaciones antropométricas observadas entre diferentes poblaciones pueden influir en la selección de los parámetros técnicos. Por ejemplo, pacientes con mayor masa corporal o con mayor densidad ósea pueden requerir ajustes en los niveles de kVp o mAs para lograr una penetración adecuada del haz y evitar imágenes con bajo contraste o alto nivel de ruido. Esta adaptación técnica resulta esencial para garantizar una adecuada calidad diagnóstica en contextos clínicos diversos.

Figura 2

Factores Técnicos de la Imagen

5. Criterios de calidad: Se tiene en cuenta el R.I.P	
R	<p>ROTACIÓN: se observan los procesos espinosos que deben encontrarse en un punto medial entre las clavículas. (Se toman las apófisis espinosas y se traza una línea medio espinosa y se observa el borde de las clavículas y se toman medidas, si esta alineada mide lo mismo de los dos lados). Se obtiene placa alineada o desalineada.</p>
I	<p>INSPIRACIÓN: se debe contar de 5 a 7 costillas anteriores o 8 a 9 costillas posteriores. Se obtiene la placa bien inspirada o mal inspirada.</p>
P	<p>PENETRACIÓN: la columna debe ser visible detrás del corazón, vasos en ápices pulmonares y a través del corazón. Se obtiene placa dura o blanda.</p>

Además se debe identificar si la placa esta en inspiración o espiración, ya que en espiración el diafragma se eleva y aparece una falsa congestión.

Nota. Factores más importantes en imagen el kVp y mAs, Tomado de Udocz, (2022).

Interacciones Físicas y Criterios de Calidad Diagnóstica

La calidad diagnóstica de una radiografía de tórax depende no solo de los parámetros técnicos utilizados durante la adquisición de la imagen, sino también del cumplimiento de criterios radiológicos estandarizados que permiten una interpretación adecuada.

Entre los principales criterios de calidad se encuentran la penetración, inspiración y simetría torácica (Felson, 2014). La penetración adecuada permite visualizar las estructuras vertebrales a través de la silueta cardíaca. Cuando la radiografía se encuentra subpenetrada (kVp insuficiente), la imagen aparece excesivamente blanca, lo que puede ocultar lesiones pulmonares o generar falsos positivos por aumento artificial de la densidad. Por el contrario, una sobrepenetración puede disminuir el contraste y dificultar la identificación de estructuras vasculares finas. La inspiración adecuada se evalúa observando el número de arcos costales posteriores visibles. En condiciones óptimas deben observarse aproximadamente entre 9 y 10 costillas posteriores, lo que indica una expansión pulmonar suficiente. Una inspiración deficiente puede simular cardiomegalia o aumentar la densidad pulmonar, generando interpretaciones erróneas.

Finalmente, la simetría torácica constituye un criterio fundamental para garantizar la correcta posición del paciente. Esta se evalúa comparando la distancia entre los extremos mediales de las clavículas y las apófisis espinosas de las vértebras torácicas. Una rotación del paciente puede producir una aparente asimetría pulmonar o modificar el tamaño aparente del mediastino, lo que podría confundirse con patologías como atelectasias o desviaciones mediastínicas. Por esta razón, el control técnico de estos parámetros es fundamental para garantizar que las imágenes radiográficas reflejen con precisión la anatomía del paciente y permitan una interpretación diagnóstica confiable.

Además de los factores técnicos propios del equipo radiográfico, las características anatómicas y antropométricas del paciente influyen significativamente en la formación de la imagen. Variables como el grosor de la pared torácica, la densidad mineral ósea y la distribución del tejido adiposo pueden modificar los niveles de atenuación del haz de rayos X. Por esta razón, el tecnólogo en radiología debe ajustar parámetros como el kVp y el mAs de acuerdo con la complejión física del paciente, con el fin de garantizar una penetración adecuada y evitar artefactos o interpretaciones diagnósticas erróneas.

Figura 3

Radiografía de Tórax con Penetración Adecuada.



Nota. Parámetros técnicos durante la adquisición de la imagen, Tomado de Blogspot, (2020)

Figura 4

Radiografía Sub-penetrada que Afecta el Contraste Estructural



Nota. Menor penetración: la radiografía se denomina placa blanda, ya que la imagen se observa demasiado blanca. Tomado de Blogspot, (2020).

Variabilidad Antropométrica y su Impacto en la Radiografía

Las características anatómicas de los pacientes pueden variar significativamente entre individuos y poblaciones, lo cual tiene implicaciones directas en la adquisición y calidad de las imágenes radiográficas. Factores como el grosor de la pared torácica, la densidad mineral ósea y la distribución del tejido adiposo influyen en el grado de atenuación del haz de rayos X, lo que puede modificar la apariencia de las estructuras anatómicas en la imagen resultante (Bushberg et al., 2012).

El grosor de la pared torácica constituye uno de los factores más relevantes en la radiografía de tórax, ya que determina la cantidad de radiación necesaria para atravesar adecuadamente el cuerpo del paciente. Estudios antropométricos han evidenciado que este parámetro puede variar según factores como el sexo, la edad y el origen étnico, lo que puede requerir ajustes en los parámetros técnicos del equipo radiológico, particularmente en los niveles de kVp y mAs, con el fin de garantizar una penetración adecuada del haz de rayos X (Shepard et al., 2014). De igual manera, la densidad mineral ósea (DMO) representa otro factor que puede influir en la absorción de la radiación.

Variabilidad Anatómica y Antropométrica Según la Etnia

Las diferencias anatómicas entre individuos y poblaciones pueden influir en la apariencia radiográfica de las estructuras torácicas. Estas variaciones incluyen diferencias en la densidad mineral ósea, el grosor de la pared torácica y la distribución del tejido adiposo.

Desde el punto de vista radiológico, estas características pueden modificar la atenuación del haz de rayos X y alterar la apariencia de las estructuras en la imagen, lo que puede afectar tanto la interpretación clínica como el desempeño de los sistemas de inteligencia artificial entrenados para analizar estas imágenes.


Densidad Mineral Ósea (DMO)

Diversos estudios han demostrado que existen diferencias significativas en la densidad mineral ósea (DMO) entre diferentes grupos étnicos. Investigaciones epidemiológicas han reportado que las poblaciones afrodescendientes tienden a presentar una mayor densidad mineral ósea en comparación con poblaciones caucásicas, lo cual se asocia con una mayor resistencia estructural del tejido óseo (Borrell & Elhawary, 2021).

Desde el punto de vista radiológico, estas diferencias pueden modificar la atenuación del haz de rayos X, ya que los tejidos con mayor densidad mineral absorben una mayor cantidad de radiación. En radiografía de tórax, esto puede traducirse en una mayor opacidad de las estructuras óseas, lo que potencialmente altera el contraste entre hueso y tejido pulmonar. Adicionalmente, estudios de densitometría han mostrado que la densidad ósea promedio en población afrodescendiente puede ser entre 5 % y 15 % superior en comparación con poblaciones caucásicas, particularmente en estructuras como costillas y columna vertebral. Estas variaciones pueden influir en la apariencia radiográfica del tórax y deben ser consideradas tanto en la interpretación clínica como en el desarrollo de algoritmos de inteligencia artificial. Cuando estas diferencias no se encuentran representadas adecuadamente en los conjuntos de datos utilizados para entrenar modelos de inteligencia artificial, existe el riesgo de que el algoritmo interprete estas variaciones fisiológicas como anomalías patológicas o reduzca su sensibilidad diagnóstica en determinados grupos poblacionales.

Figura 5

Densidad Mineral Ósea (DMO)



Nota. Diferencias significativas en la densidad mineral ósea (DMO). Tomado de Shutterstock, (2020)

Composición del Tejido Blando

Las variaciones en el espesor de la pared torácica y en la distribución de grasa pectoral pueden producir sombras mamarias o superposiciones anatómicas que imitan enfermedades pulmonares Oakden-Rayner et al. (2020) señalan que la estratificación encubierta en los conjuntos de datos puede generar errores clínicamente relevantes si no se tienen en cuenta subgrupos anatómicamente diferentes durante el entrenamiento de modelos de inteligencia artificial.

Figura 6

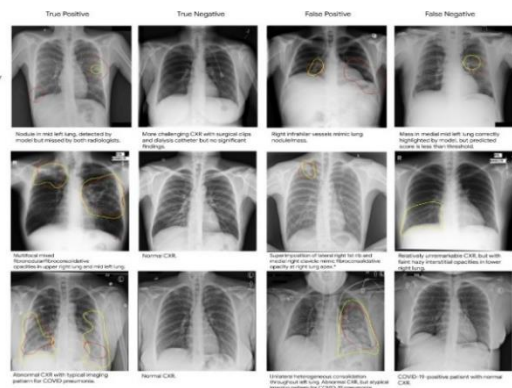
Enfermedades Pulmonares



Nota. Variaciones en la composición del tejido blando, Tomado de Clavero, (2015)

Figura 7

Variabilidad Anatómica Torácica



Nota. Variabilidad anatómica en radiografía de tórax, tomada de (Afzali, 2018)

Estratificación Encubierta

Un fenómeno relevante en el análisis de datos médicos es la estratificación encubierta (hidden stratification). Este concepto describe situaciones en las que un modelo de inteligencia artificial muestra un alto rendimiento global, pero presenta errores significativos cuando se analizan subgrupos específicos dentro de la población (Oakden-Rayner et al., 2020). Por ejemplo, un algoritmo entrenado para detectar neumonía en radiografías de tórax puede mostrar

una precisión general superior al 90 %. Sin embargo, al evaluar su rendimiento en subpoblaciones particulares, como pacientes con mayor grosor de la pared torácica o diferentes proporciones anatómicas, el desempeño puede disminuir considerablemente. Este fenómeno ocurre porque el modelo aprende patrones predominantes en el conjunto de datos de entrenamiento, los cuales no necesariamente representan toda la diversidad anatómica de la población real.

Bases de Datos Utilizadas en Inteligencia Artificial Radiológica

El desarrollo de algoritmos de inteligencia artificial en radiología se ha apoyado principalmente en grandes bases de datos públicas de imágenes médicas. Entre las más utilizadas se encuentran MIMIC-CXR y ChestX-ray14, las cuales contienen cientos de miles de radiografías de tórax utilizadas para el entrenamiento y validación de modelos de aprendizaje profundo (Johnson et al., 2019; Wang et al., 2017). La base de datos MIMIC-CXR contiene más de 370.000 radiografías de tórax correspondientes a aproximadamente 65.000 pacientes, acompañadas de reportes radiológicos estructurados. Por su parte, ChestX-ray14 incluye más de 100.000 estudios radiográficos etiquetados con 14 patologías torácicas comunes.

Aunque estas bases han sido fundamentales para el avance de la inteligencia artificial en radiología, presentan limitaciones importantes relacionadas con la disponibilidad de variables demográficas detalladas, como etnia o características antropométricas. Esta falta de información dificulta evaluar si los algoritmos presentan un rendimiento diagnóstico uniforme en todos los grupos poblacionales.

Limitaciones de las Bases de Datos Utilizadas

A pesar de que bases de datos como MIMIC-CXR y ChestX-ray14 han jugado un papel crucial en el avance de los algoritmos de inteligencia artificial en radiología, estas tienen ciertas

limitaciones relevantes. En primer lugar, gran parte de estas bases se edificaron con datos originados principalmente de hospitales en Estados Unidos, lo que sugiere que la información representa primordialmente poblaciones concretas y no necesariamente muestra la diversidad global.

Asimismo, estas bases de datos tienden a incluir información demográfica restringida, lo que complica el análisis del rendimiento de los algoritmos en función de variables como etnia, rasgos antropométricos o situaciones socioeconómicas. La ausencia de representatividad puede conducir a sesgos en los modelos de inteligencia artificial, perjudicando su exactitud diagnóstica cuando se utilizan en contextos distintos, como el colombiano o el latinoamericano

Sesgo de Datos (Data Bias)

El sesgo de datos ocurre cuando los conjuntos de entrenamiento no representan adecuadamente la diversidad poblacional.

Bases de datos ampliamente utilizadas como:

MIMIC-CXR (Johnson et al., 2019)

NIH ChestX-ray14 (Wang et al., 2017).

Han sido fundamentales en el desarrollo de modelos de inteligencia artificial en radiología. No obstante, estas bases presentan limitaciones en la documentación de variables demográficas, lo que dificulta analizar el desempeño diferencial de los algoritmos según grupo étnico. Zechetal (2018) demostraron que los modelos pueden aprender patrones institucionales en lugar de características clínicas reales, lo que reduce su capacidad de generalización entre hospitales.

Figura 8

Inteligencia Artificial en Radiología



Nota. La identificación y la comprensión de las raíces del sesgo en la inteligencia artificial, Tomado de Hernandez, (2024)

Precisión Diagnóstica Diferencial

Obermeyer et al. (2019) demostraron que un algoritmo del sistema de salud de Estados Unidos subestimaba el riesgo en pacientes afrodescendientes, debido a variables indirectas utilizadas como indicadores de salud. Esto evidencia que los algoritmos pueden reproducir inequidades existentes en los sistemas de salud.

Figura 9

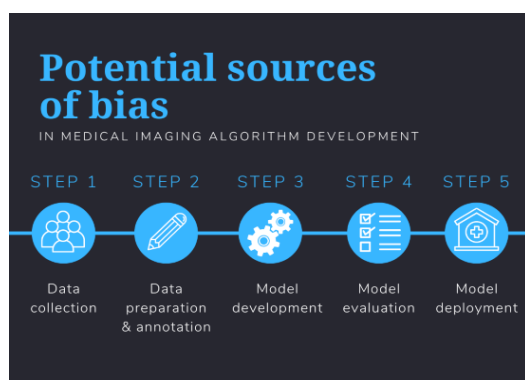
Análisis de Sesgo



Nota. resultados de identificación automática de enfermedades a través del análisis de imágenes clínicas. Tomado de Benito, (2020)

Figura 10

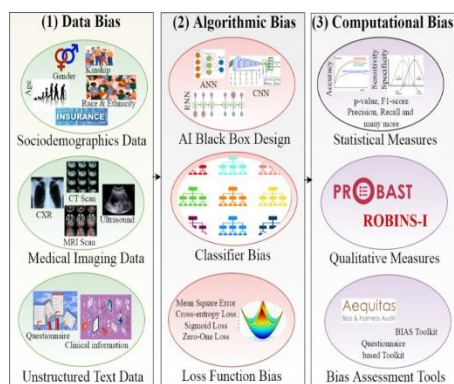
Sesgos en Algoritmos de Diagnóstico y Equidad en Salud



Nota. Los algoritmos de diagnóstico pueden exhibir sesgos si los datos de entrenamiento no reflejan adecuadamente la diversidad de la población, tomado de Obermeyer et al., (2019).

Figura 11

Impacto de la Inteligencia Artificial en la Equidad en Salud



Nota. La valoración de la inteligencia artificial en diferentes poblaciones es esencial para asegurar justicia en la atención sanitaria, tomada de Norori et al., (2021)

Representatividad en la Literatura Médica y Bases de Datos

Johnson et al. (2019) analizan la estructura de la base de datos MIMIC-CXR, destacando su gran magnitud y utilidad para el desarrollo de algoritmos. Sin embargo, la falta de información demográfica detallada limita el análisis de equidad diagnóstica. De manera similar,

Wang et al. (2017) desarrollaron la base ChestX-ray14, ampliamente utilizada en investigación, aunque con limitaciones similares en representatividad poblacional. La carencia de diversidad en los conjuntos de datos dificulta determinar si el rendimiento del algoritmo es uniforme en todos los grupos de población, lo que tiene implicaciones éticas y clínicas importantes.

La representación en la literatura médica es esencial para asegurar que los progresos tecnológicos en salud favorezcan de forma justa a todas las comunidades. No obstante, varios estudios han indicado que una gran parte de la investigación médica y tecnológica se fundamenta en datos de poblaciones de naciones desarrolladas, lo que puede provocar una subrepresentación de comunidades de otras áreas del planeta. Este escenario puede influir en la creación de algoritmos de inteligencia artificial, puesto que los modelos desarrollados con datos poco variados pueden mostrar menor precisión diagnóstica al usarse en poblaciones con diferentes características biológicas y sociales.

Figura 12

Porcentaje Demográfico



Nota. Creación de algoritmos de inteligencia artificial desarrollados con datos, tomado de Freepik.es, (2015)

Integración Crítica y Aportes Investigativos

La integración crítica de la literatura analizada muestra que el progreso de la inteligencia artificial en radiología no se basa solo en avances tecnológicos, sino también en la calidad y

variedad de los datos empleados para entrenar los modelos. Varios autores concuerdan en que los algoritmos pueden perpetuar las desigualdades existentes en los sistemas de salud si no se gestionan correctamente los sesgos que hay en los conjuntos de datos.

De igual manera, los estudios revisados muestran que elementos como la variabilidad anatómica, las diferencias antropométricas entre grupos y la ausencia de representación de determinados grupos étnicos pueden afectar el rendimiento diagnóstico de los sistemas automatizados. Por esta razón, la literatura científica sugiere la adopción de estrategias como auditorías de equidad, validación multicéntrica de algoritmos y creación de bases de datos más variadas.

Estos estudios indican que el uso responsable de la inteligencia artificial en el ámbito de la salud demanda no solo avances tecnológicos, sino también un enfoque ético y social que asegure la igualdad en la atención médica

La integración de evidencia obtenida en español con literatura internacional permite identificar tres aspectos clave:

La calidad técnica de una radiografía de tórax depende de factores físicos, biológicos y sociales.

La variabilidad anatómica poblacional tiene impacto diagnóstico real.

El uso de inteligencia artificial en diagnóstico requiere validación contextual y diversidad poblacional para evitar sesgos.

Impacto en el Contexto Colombiano

En el contexto colombiano, la implementación de inteligencia artificial en radiología debe considerar la diversidad étnica y antropométrica de la población. Colombia es un país con una composición poblacional heterogénea que incluye poblaciones mestizas, afrodescendientes e

indígenas, cada una con características biológicas y socioeconómicas particulares. Si los algoritmos utilizados en sistemas de apoyo diagnóstico son entrenados principalmente con bases de datos provenientes de poblaciones norteamericanas o europeas, existe el riesgo de que su desempeño no sea equivalente en la población colombiana. Esto podría generar diferencias en la precisión diagnóstica y afectar la equidad en la atención en salud.

Por lo tanto, resulta necesario promover investigaciones que evalúen el rendimiento de estos sistemas en poblaciones locales y fomentar la creación de bases de datos médicas representativas de la diversidad demográfica del país.

En Colombia, la integración de inteligencia artificial en radiología todavía está en una etapa de investigación y desarrollo. No obstante, la nación muestra una amplia diversidad cultural y étnica que abarca comunidades indígenas, afrodescendientes y mestizas, lo que requiere una evaluación cuidadosa de la aplicabilidad de los algoritmos creados en otros contextos.

Si los sistemas de inteligencia artificial aplicados en el diagnóstico radiológico son entrenados mayormente con datos de poblaciones europeas o norteamericanas, hay un riesgo de que su rendimiento no sea del todo apropiado para la población colombiana. Por ello, es crucial impulsar estudios nacionales que faciliten la validación de estos sistemas en entornos locales y que propicien la creación de bases de datos médicas que representen la diversidad de la población del país.

Marco Metodológico

El presente estudio se desarrolló bajo un enfoque cualitativo, de tipo documental y con un diseño descriptivo-analítico, basado en la revisión de literatura científica.

Fase 1: Proceso de Búsqueda de la Información

Se realizó una búsqueda sistemática de literatura en bases de datos científicas como PubMed, ScienceDirect y SciELO.

Se emplearon descriptores clave como: radiografía de tórax, inteligencia artificial, sesgos algorítmicos, variabilidad antropométrica, equidad en salud. Asimismo, se utilizaron combinaciones mediante operadores booleanos (AND, OR) para ampliar y precisar los resultados.

Fase 2: Análisis de los Artículos

Se seleccionaron artículos científicos teniendo en cuenta los siguientes criterios: Publicaciones en revistas indexadas, Rango de años: (puedes poner: 2015–2025), Idiomas: español e inglés, Pertinencia con el tema de estudio

Se priorizaron estudios relacionados con inteligencia artificial en radiología, sesgos algorítmicos y variabilidad poblacional.

Fase 3: Análisis de la Información

Se realizó un análisis crítico de la información recopilada.

Criterios de Inclusión

Artículos científicos relevantes

Estudios sobre IA en salud

Investigaciones sobre sesgos y variabilidad anatómica

Criterios de Exclusión

Fuentes no académicas

Información desactualizada

Artículos sin relación directa con el tema

Finalmente, se interpretaron los hallazgos para establecer la relación entre la variabilidad anatómica y los sesgos en inteligencia artificial en radiología.

Diagrama de Flujo

Inicio → Identificación del problema → Definición de palabras clave → Búsqueda en bases de datos (PubMed, SciELO, ScienceDirect) → Selección de artículos (Criterios de inclusión/exclusión) → Análisis de artículos → Síntesis de la información → Interpretación de resultados → Conclusiones → Fin

Análisis de Resultados

A partir del análisis de la literatura científica publicada entre 2015 y 2025, se exponen los resultados organizados de acuerdo con los objetivos específicos del estudio.

Objetivo 1: Principios Técnicos de la Radiografía Torácica y su Conexión con la Variabilidad Anatómica

La evaluación mostró que la calidad del diagnóstico de una radiografía de tórax está influenciada por la combinación de los parámetros técnicos del equipo y las características biológicas del paciente. El kilovoltaje de pico (kVp) y el miliamperaje por segundo (mAs) establecen la energía y el número de fotones emitidos, que interactúan con los tejidos a través del efecto fotoeléctrico y la dispersión Compton (Bushberg et al., 2012; Shepard et al., 2014). Una penetración insuficiente puede resultar en imágenes de calidad inferior que oculten lesiones o generen densidades erróneas, afectando la exactitud del diagnóstico (Felson, 2014).

Se determinó que la variabilidad anatómica entre diferentes poblaciones influye de manera directa en estos niveles de atenuación. Elementos como el grosor de la pared torácica, la densidad mineral ósea y la configuración del tejido adiposo requieren modificaciones personalizadas en los parámetros técnicos (Bushberg et al., 2012; Shepard et al., 2014). Si estos ajustes no se ejecutan correctamente, la imagen obtenida puede no reflejar con exactitud la anatomía del paciente, creando circunstancias que propician errores de interpretación en la evaluación tanto por humanos como en el análisis automatizado (Mehrabi et al., 2021).

Objetivo 2: Variaciones Anatómicas y Antropométricas entre Diversos Grupos de Población

La literatura consultada muestra variaciones notables en la estructura corporal entre grupos étnicos, con repercusiones directas en la imagen radiográfica. Investigaciones de

densitometría han registrado que la densidad mineral ósea en grupos afrodescendientes puede ser entre un 5 % y un 15 % más alta que en grupos caucásicos, especialmente en estructuras como la columna vertebral y costillas (Borrell & Elhawary, 2021). Esa mayor densidad provoca una mayor absorción del haz de rayos X, lo que resulta en una opacidad ósea aumentada que puede modificar el contraste entre estructuras óseas y tejido pulmonar (Bushberg et al., 2012).

Asimismo, las fluctuaciones en el grosor de la pared torácica y en la distribución de la grasa en el pecho pueden causar superposiciones anatómicas que imitan enfermedades pulmonares (Shepard et al., 2014). Oakden-Rayner et al. (2020) indican que estas variaciones forman subgrupos anatómicamente diferentes, cuya falta en los datos de entrenamiento de los algoritmos origina errores clínicos significativos. Estos resultados respaldan que la variabilidad anatómica en la población no es un aspecto menor, sino una variable con un impacto diagnóstico concreto y cuantificable (Seyyed-Kalantari et al., 2021).

Objetivo 3: Prejuicios en Algoritmos de Inteligencia Artificial y su Efecto en el Diagnóstico

El estudio de la literatura reveló que los sesgos en los algoritmos de inteligencia artificial en radiología provienen de múltiples factores, relacionados tanto con restricciones técnicas en el desarrollo de los modelos como con fallos estructurales en los conjuntos de datos empleados para su entrenamiento (Mehrabi et al., 2021).

Las bases de datos más comunes en la creación de estos algoritmos, MIMIC-CXR y ChestX-ray14, son en su mayoría de hospitales de EE. UU. y tienen una documentación demográfica limitada, con poca información sobre etnicidad o rasgos antropométricos de los pacientes (Johnson et al., 2019; Wang et al., 2017). Esta restricción imposibilita determinar si el desempeño diagnóstico de los algoritmos es consistente entre diversos grupos poblacionales.

Seyyed-Kalantari et al. (2021) demostraron que estos sistemas tienen una menor sensibilidad diagnóstica en grupos subrepresentados, lo que resulta en un aumento de la tasa de falsos negativos para identificar patologías torácicas. Este fenómeno está vinculado a la estratificación oculta: un modelo puede lograr una precisión general por encima del 90 %, pero mostrar un desempeño mucho más bajo al ser evaluado en subgrupos con rasgos anatómicos particulares no incluidos en el entrenamiento (Oakden-Rayner et al., 2020). La subida de falsos negativos en estas comunidades conlleva diagnósticos retrasados, demoras en el comienzo del tratamiento y un incremento del riesgo de complicaciones, lo que representa un efecto directo en la seguridad del paciente (Norori et al., 2021).

Larrazabal et al. (2020) mostraron que el desequilibrio en la composición de los conjuntos de datos produce clasificadores sesgados desde la fase de entrenamiento, mientras que Obermeyer et al. (2019) comprobaron que estos sistemas no solo replican las desigualdades ya presentes en los sistemas de salud, sino que pueden intensificarlas. En el contexto colombiano, esta situación cobra particular importancia porque la población muestra una variedad étnica y antropométrica que no está reflejada en las bases de datos internacionales más comunes, restringiendo así la implementación directa de estos algoritmos en el país (Norori et al., 2021; Mehrabi et al., 2021).

A partir de la revisión documental, se identifican similitudes y diferencias entre los enfoques de los autores, las cuales se sintetizan en la siguiente tabla

Tabla 1

Comparación de Enfoques sobre Sesgos en Inteligencia Artificial en Radiología

Autor(es)	Hallazgos clave	Enfoque comparativo	Soluciones
Obermeyer et al. (2019)	La IA amplifica desigualdades en salud	Enfoque social y estructural	Redefinir variables

Autor(es)	Hallazgos clave	Enfoque comparativo	Soluciones
Larrazabal et al. (2020)	Desbalance de datos genera sesgos	Enfoque técnico	Balanceo de datos
Seyyed-Kalantari et al. (2021)	Menor precisión en poblaciones vulnerables	Evidencia clínica directa	Evaluación por subgrupos
Norori et al. (2021)	Falta de diversidad afecta equidad	Enfoque ético	Datos inclusivos
Mehrabi et al. (2021)	Sesgos en todas las fases del modelo	Enfoque integral	Mitigación en diseño

Nota: Elaboración propia a partir de la revisión bibliográfica

El análisis evidencia que existe consenso entre los autores en cuanto a la presencia de sesgos en los sistemas de inteligencia artificial. Sin embargo, se identifican diferencias en el enfoque desde el cual explican su origen, ya que algunos lo abordan desde una perspectiva técnica centrada en los datos, mientras que otros lo relacionan con desigualdades estructurales en salud. A pesar de estas diferencias, coinciden en la necesidad de desarrollar modelos más inclusivos que garanticen equidad y precisión diagnóstica.

Con el fin de profundizar en la relación entre los factores técnicos, la variabilidad anatómica y su impacto en los sistemas de inteligencia artificial, se presenta la siguiente tabla

Tabla 2

Relación entre Factores Técnicos, Variabilidad Anatómica e Implicaciones en Inteligencia Artificial

Aspecto	Factores técnicos (kVp – mAs)	Variabilidad anatómica	Implicaciones en IA
Definición	Controlan energía y cantidad de radiación	Diferencias físicas del paciente	Capacidad de interpretación del algoritmo
Influencia en la imagen	Determinan contraste, penetración y ruido	Modifican la atenuación	Afectan calidad de los datos de entrada
Relación	Deben ajustarse al paciente	Requieren adaptación técnica	Generan datos más o menos confiables
Problema	Protocolos estándar	Alta variabilidad poblacional	Sesgos en el modelo
Impacto clínico	Imagen subóptima	Pérdida de detalle	Errores diagnósticos
Soluciones	Ajuste individualizado	Considerar antropometría	Datos diversos y validación

Nota: Elaboración propia a partir de la revisión bibliográfica de Bushberg et al. (2012), Shepard et al. (2014), Norori et al. (2021) y Mehrabi et al. (2021).

El análisis evidencia que los factores técnicos y la variabilidad anatómica están estrechamente relacionados en la formación de la imagen radiográfica. La falta de ajuste de parámetros como el kVp y el mAs frente a las características del paciente puede generar imágenes de baja calidad, lo que impacta directamente en el desempeño de los algoritmos de inteligencia artificial. En este sentido, se resalta la necesidad de integrar protocolos individualizados y bases de datos diversas para mejorar la precisión diagnóstica.

Con el propósito de ampliar la perspectiva de la investigación, se presenta un análisis comparativo sobre el abordaje de los sesgos algorítmicos en radiología en distintos países, identificando avances y desafíos relacionados con la equidad en salud y el uso de inteligencia artificial.

Conclusiones

A partir del análisis comparativo de la literatura académica revisada, se exponen las siguientes conclusiones en relación al objetivo general del estudio.

Primero, se determina que el desempeño de los algoritmos de inteligencia artificial en radiología torácica no es únicamente un tema tecnológico, sino que depende en gran medida de la comprensión de los factores físicos y biológicos que influyen en la creación de la imagen. La variación anatómica entre diferentes grupos poblacionales, manifestada en discrepancias de densidad mineral ósea, grosor de la pared torácica y composición de tejidos blandos, influye en la atenuación del haz de rayos X y afecta la calidad diagnóstica de la imagen obtenida. Cuando estas variaciones no se reflejan en los datos de entrenamiento, el algoritmo no posee los patrones requeridos para entenderlas adecuadamente, lo que provoca errores sistemáticos en el diagnóstico de poblaciones subrepresentadas. La relación entre técnica radiográfica, biología humana y rendimiento algorítmico es el hallazgo principal de esta investigación.

En segundo lugar, se llega a la conclusión de que es imperativo aumentar la diversidad poblacional en las bases de datos empleadas para el entrenamiento de modelos de inteligencia artificial en el ámbito de la salud. Las bases de datos más comunes en radiología, desarrolladas principalmente con datos de hospitales en EE. UU., no capturan la diversidad biológica, étnica y antropométrica de la población mundial. Esta restricción estructural afecta la validez externa de los algoritmos y mantiene desigualdades en los diagnósticos que impactan de manera desiguales a grupos históricamente subrepresentados. La incorporación intencionada de diversidad demográfica en los conjuntos de datos no es solo un avance técnico, sino una obligación ética para asegurar la equidad en salud.

En tercer lugar, en el contexto colombiano, esta cuestión toma una dimensión particular que no puede ser pasada por alto. Colombia posee una diversidad poblacional que abarca comunidades mestizas, afrodescendientes e indígenas, cada una con rasgos biológicos y antropométricos específicos. Los algoritmos creados y comprobados en contextos norteamericanos o europeos no pueden ser considerados directamente aplicables a esta realidad sin una validación local exhaustiva.

Finalmente, se determina que la aplicación clínica de la inteligencia artificial en radiología debe ser obligatoriamente acompañada de auditorías sistemáticas de equidad, validación en subgrupos de población y evaluaciones críticas periódicas del rendimiento de los modelos en situaciones reales. Estas auditorías deben analizar no solo la exactitud general del algoritmo, sino su eficacia variada entre grupos étnicos, de género, edad y rasgos antropométricos. Únicamente a través de este enfoque integral se podrá asegurar que las innovaciones tecnológicas en radiología favorezcan una atención en salud más justa, segura y equitativa para todas las comunidades.

Referencias

- Afzali, A., Babapour-Mofrad, F., & Pouladian, M. (2018). Inter-patient modelling of 2D lung variations from chest X-ray imaging via Fourier descriptors. *Journal of Medical Systems*, 42(11), 233. <https://doi.org/10.1007/s10916-018-1058-7>
- Banerjee, I., Bhimireddy, A. R., Krishnan, R., & Pan, I. (2021). Reading race: AI recognises patient's racial identity in medical images. *The Lancet Digital Health*, 3(10), e626–e627. [https://doi.org/10.1016/S2589-7500\(21\)00240-7](https://doi.org/10.1016/S2589-7500(21)00240-7)
- Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. *Proceedings of Machine Learning Research*, 81, 1–15.
- Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2012). *The essential physics of medical imaging* (3rd ed.). Lippincott Williams & Wilkins.
- Corredor, E. S. (2018). *Técnicas de investigación: Identificación del problema*. <https://repository.unad.edu.co/handle/10596/22997>
- Drukker, K., Giger, M. L., & others. (2023). Toward fairness in artificial intelligence for medical image analysis. *Radiology: Artificial Intelligence*, 5(3). <https://doi.org/10.1148/ryai.220296>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & 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>
- Felson, B. (2014). *Felson's principles of chest roentgenology: A programmed text* (4th ed.). Elsevier Saunders.

González, S., Sánchez, M., & Hernández, R. (2023). Árbol de problemas como base en la investigación. *Educación y Salud*, 12(23), 125–129.

<https://repository.uaeh.edu.mx/revistas/index.php/ICSA/article/download/11153/10729/>

Guerrero, K. A. (2024). *Cómo plantear una pregunta de investigación* [Objeto virtual de aprendizaje]. Repositorio Institucional UNAD.

<https://repository.unad.edu.co/handle/10596/64468>

Hernández, A., Rangel, M., García, L., Hernández, G., Castillo, P., Olivares, L., & Sánchez, A. (2022). Proceso para la realización de una revisión bibliográfica en investigaciones clínicas. *Digital Ciencia*, 15(1), 50–61.

Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.

Hussain, S. A., Bresnahan, M., & Zhuang, J. (2025). The bias algorithm: How AI in healthcare exacerbates ethnic and racial disparities. *Ethnicity & Health*.

Johnson, A. E. W., Pollard, T. J., Berkowitz, S. J., Greenbaum, N. R., Lungren, M. P., Deng, C. Y., Mark, R. G., & 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>

Lancheros, E. (2023). *Cómo elaborar un planteamiento de problema sólido y convincente* [Objeto virtual de información]. Repositorio Institucional UNAD.

<https://repository.unad.edu.co/handle/10596/57735>

Larrazabal, A. J., Nieto, N., Peterson, V., Milone, D. H., & Ferrante, E. (2020). Gender imbalance in medical imaging datasets produces biased classifiers. *Proceedings of the*

National Academy of Sciences, 117(23), 12592–12594.

<https://doi.org/10.1073/pnas.1919012117>

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>

Norori, N., Hu, Q., Aellen, F. M., Faraci, F. D., & Tzovara, A. (2021). Addressing bias in big data and AI for health care: A call for open science. *Patterns*, 2(10), 100347.

<https://doi.org/10.1016/j.patter.2021.100347>

Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447–453.

<https://doi.org/10.1126/science.aax2342>

Ortiz, J. (2022). *Árbol de problemas como metodología para la identificación de problemas de investigación en salud*. <https://repository.unad.edu.co/handle/10596/50047>

Seyyed-Kalantari, L., Liu, G., McDermott, M. B. A., Chen, I. Y., & Ghassemi, M. (2021).

Underdiagnosis bias of artificial intelligence algorithms applied to chest radiographs.

Nature Medicine, 27(12), 2176–2182. <https://doi.org/10.1038/s41591-021-01595-0>

Shepard, S. J., Linnau, K. F., & Starr, F. (2014). *Radiographic imaging and exposure* (5th ed.).

Elsevier.

Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-ray8:

Hospital-scale chest X-ray database and benchmarks on weakly supervised classification and localization of common thorax diseases. *Proceedings of the IEEE Conference on*

Computer Vision and Pattern Recognition. <https://doi.org/10.1109/CVPR.2017.369>