

Desigualdad de género en los datos: Un reto para la Inteligencia Artificial y el diseño de fármacos

Fernanda I. Saldívar-González* y Ana C. Murrieta*

Resumen

La investigación biomédica ha estado marcada por sesgos de sexo y género que han impuesto el modelo androcéntrico como norma, propiciando la exclusión histórica de mujeres, poblaciones trans y otros grupos. Estos sesgos representan desviaciones estructurales que no solo distorsionan la objetividad científica, sino que también afectan de manera directa el diseño, desarrollo y aplicación clínica de los fármacos, comprometiendo su seguridad, eficacia y equidad. Tales limitaciones restringen el potencial de la medicina traslacional y ponen en duda las promesas de la inteligencia artificial (IA) para impulsar tratamientos personalizados y más seguros. Este artículo examina las raíces de esta problemática, presenta ejemplos de medicamentos que evidencian dichos sesgos y analiza su impacto en los modelos predictivos basados en IA. Asimismo, se destacan iniciativas computacionales emergentes orientadas a promover una medicina más equitativa, e inclusiva.

Palabras clave

Medicina traslacional, diseño de fármacos, investigación biomédica, inteligencia artificial, sesgo de género

Abstract

Biomedical research has historically been influenced by sex and gender biases that have established an androcentric model as the norm, leading to the systematic exclusion of women, trans populations, and other groups. These biases constitute structural deviations that not only distort scientific objectivity but also directly affect the design, development, and clinical application of drugs, thereby compromising their safety, efficacy, and equity. Such limitations constrain the potential of translational medicine and call into question the promises of artificial intelligence (AI) to advance more personalized and safer treatments. This article examines the roots of this issue, presents examples of drugs that illustrate these biases, and analyzes their impact on AI-based predictive models. It also highlights emerging computational initiatives aimed at promoting a more equitable, inclusive, and responsible approach to medicine.

Keywords

Translational medicine, drug design, biomedical research, artificial intelligence, gender bias

* Tecnológico de Monterrey, Institute for Obesity Research, Unidad de Medicina Experimental, Monterrey, Nuevo León, México.
E-mail: fer.saldivarg@tec.mx



Introducción

Durante décadas, el desarrollo de fármacos ha estado marcado por una preocupante falta de inclusión. Comunidades racializadas, pueblos indígenas y, de forma particularmente notable, las mujeres y las poblaciones trans han sido sistemáticamente subrepresentadas en la investigación biomédica, lo que ha comprometido la seguridad, la eficacia y la equidad de los tratamientos médicos. En estos grupos, los sesgos vinculados al sexo biológico (diferencias fisiológicas) y al género (construcciones sociales y expectativas culturales) han estado presentes tanto en el desarrollo de fármacos como en su uso clínico. Estos sesgos al ser desviaciones sistemáticas no solo distorsionan la objetividad científica, sino que también reflejan y reproducen desigualdades estructurales de orden social, económico y cultural, favoreciendo o excluyendo a determinados grupos a través de la producción del conocimiento y de sus aplicaciones médicas.

Por ejemplo, en los estudios preclínicos, que abarcan experimentos en modelos animales para evaluar el potencial terapéutico de una sustancia, se estima que aproximadamente el 80% de estos emplean exclusivamente animales machos, incluso para enfermedades que afectan predominantemente a las mujeres (Yoon *et al.*, 2014). Esta elección se ha justificado en supuestas ventajas metodológicas, menores costos y preocupaciones éticas relacionadas con posibles exposiciones durante la gestación. Además, las fluctuaciones hormonales de las hembras han sido percibidas como una fuente de variabilidad que podría dificultar la obtención y análisis de resultados, lo que ha llevado a su exclusión sistemática de numerosos estudios (Allegra *et al.*, 2023).

En forma paralela, y sustentada por el temor a posibles riesgos reproductivos, esta exclusión se trasladó a la investigación clínica en humanos (Liu and Dipietro Mager, 2016). Durante años se prohibió la participación de todas las mujeres en edad fértil en las fases tempranas de investigación, incluso a aquellas con métodos anticonceptivos o sin posibilidad de embarazo. Si bien en 1993 se estableció formalmente la inclusión de mujeres en los ensayos clínicos, este cambio no vino acompañado de políticas públicas sólidas ni de modificaciones regulatorias en las etapas preclínicas que aseguraran una inclusión real. Como consecuencia, la participación de cuerpos feminizados (animales y humanos) en la investigación biomédica sigue siendo insuficiente, lo que debilita el potencial de la medicina traslacional para convertir los hallazgos de la investigación básica en intervenciones clínicas eficaces para toda la población (Holdcroft A, 2007).

A ello se suman los sesgos de género en el diagnóstico y en la práctica clínica, que inciden directamente en la forma en que los tratamientos se prescriben y aplican. La subestimación del dolor en mujeres, la interpretación errónea de síntomas en enfermedades cardiovasculares o la falta de consideración de condiciones específicas de la salud de la mujer son ejemplos de cómo el sesgo atraviesa no solo la producción del conocimiento, sino también su implementación en la atención médica.



Estas omisiones históricas y la generalización del cuerpo masculino como norma perpetúan inequidades y reducen la calidad de los datos que sustentan el desarrollo de nuevas tecnologías, especialmente aquellas basadas en inteligencia artificial (IA). La IA, entendida como un conjunto de técnicas computacionales que aprenden a partir de grandes volúmenes de datos para reconocer patrones y apoyar decisiones complejas como el diseño de fármacos, depende en gran medida de la calidad y representatividad de la información que la alimenta (Saldívar-González et al., 2023). Cuando los sistemas de IA se entrenan con datos sesgados o sin mecanismos para corregirlos, sus promesas, como el desarrollo de fármacos más seguros y la medicina personalizada, se ven comprometidas, reproduciendo o incluso profundizando desigualdades preexistentes.

Reconocer y abordar estos desafíos no solo es urgente, sino que constituye una oportunidad para orientar la ciencia hacia prácticas más justas e inclusivas. En este marco, el presente trabajo se propone analizar las raíces de las desigualdades vinculadas al sexo biológico y al género en la investigación biomédica, así como examinar cómo afectan la eficacia, la seguridad y la equidad de los tratamientos médicos. Más allá de describir la problemática, el estudio busca también identificar estrategias y herramientas computacionales que puedan contribuir a mitigar estos sesgos.

Para cumplir estos objetivos, se analizaron 40 artículos científicos publicados entre 2019 y 2025, indexados en JCR o SCIE, centrados en

los sesgos de sexo y género en biomedicina e inteligencia artificial. El estudio se enfocó específicamente en enfermedades cardiovasculares, neurodegenerativas y en el manejo del dolor. En los trabajos relacionados con IA se identificaron las etapas críticas donde surgen sesgos y se revisaron herramientas computacionales destinadas a su mitigación, lo que permitió vincular la comprensión de las desigualdades con posibles soluciones tecnológicas.

Una historia de exclusión sistemática

Aunque la desigualdad de género en la investigación biomédica suele presentarse como un fenómeno accidental o como una consecuencia de limitaciones técnicas o metodológicas, en realidad responde a un entramado de decisiones históricas, sociales e institucionales profundamente atravesadas por sesgos de género.

Lamentablemente, la ciencia no siempre es tan neutral como aparenta. Muchas veces esa supuesta objetividad se usa para sostener ideas dicotómicas y de subordinación sobre el cuerpo y el género. Un ejemplo de ello es la teoría del dimorfismo sexual y su versión contemporánea, el neodimorfismo,¹ utilizadas para justificar la existencia de diferencias biológicas innatas, fijas y universales entre los cuerpos de hombres y mujeres cisgénero. Si bien, en principio esta teoría podría incentivar investigaciones sobre cómo dichas diferencias influyen en ámbitos como el diagnóstico y el tratamiento de diversas enfermedades, en la práctica ha servido como base para sostener una lógica excluyente que margina sistemáticamente a los cuerpos feminizados, tanto humanos como animales, en la investigación científica y otras esferas de la sociedad.

¹ El dimorfismo sexual se refiere a las diferencias físicas y biológicas observables entre machos y hembras. Lu Ciccia, en *La inversión de los sexos*, menciona el neodimorfismo, como la teoría que sugiere que las hormonas prenatales pueden influir en el desarrollo del cerebro y en algunas diferencias innatas de comportamiento y capacidades.



Esta exclusión no puede entenderse como una simple decisión metodológica neutral cuando se parte del supuesto de un dimorfismo sexual determinante. Así, lejos de ser una teoría meramente descriptiva, el dimorfismo sexual ha sido expuesto por diversas autoras como Anne Fausto Sterling y Lu Ciccía como una construcción ideológica que, desde una mirada androcéntrica, presenta el cuerpo y el conocimiento científico de forma fija, binaria y jerárquica (Fausto-Sterling Anne, 2000; Ciccía, 2022). De este modo, traslada a los cuerpos la división social entre “lo masculino” y “lo femenino” y hace que la desigualdad parezca un resultado inevitable de la biología.

Por otra parte, la introducción de las hormonas sexuales en el discurso científico permitió establecer un vínculo causal entre el sexo biológico y el rol social, reforzando la idea de que las diferencias biológicas determinan de forma natural los comportamientos, capacidades y funciones de los géneros.

En su obra *La mujer hormonal*, Nelly Oudshoorn explica cómo se fue construyendo la idea de que el cuerpo femenino debía entenderse como “naturalmente hormonal” (Oudshoorn, 1997). Esta visión no nació de un descubrimiento científico neutro, sino de circunstancias sociales y materiales muy concretas. Por ejemplo, durante gran parte del siglo XX era mucho más fácil acceder a tejidos biológicos de mujeres, sobre todo ovarios y orina, que a materiales equivalentes de hombres. Esa abundancia facilitó tanto la investigación como la comercialización de las llamadas “hormonas sexuales femeninas”.

El propio término “hormonas sexuales” refleja esta mirada sesgada: se asumía que estas sustancias eran exclusivas de un sexo cuando, en realidad, mujeres y hombres producen los mismos tipos de hormonas, aunque en proporciones y

combinaciones distintas. La falta de materiales masculinos comparables frenó el estudio de las hormonas en los hombres y reforzó la idea de que “lo hormonal” estaba ligado casi exclusivamente a las mujeres.

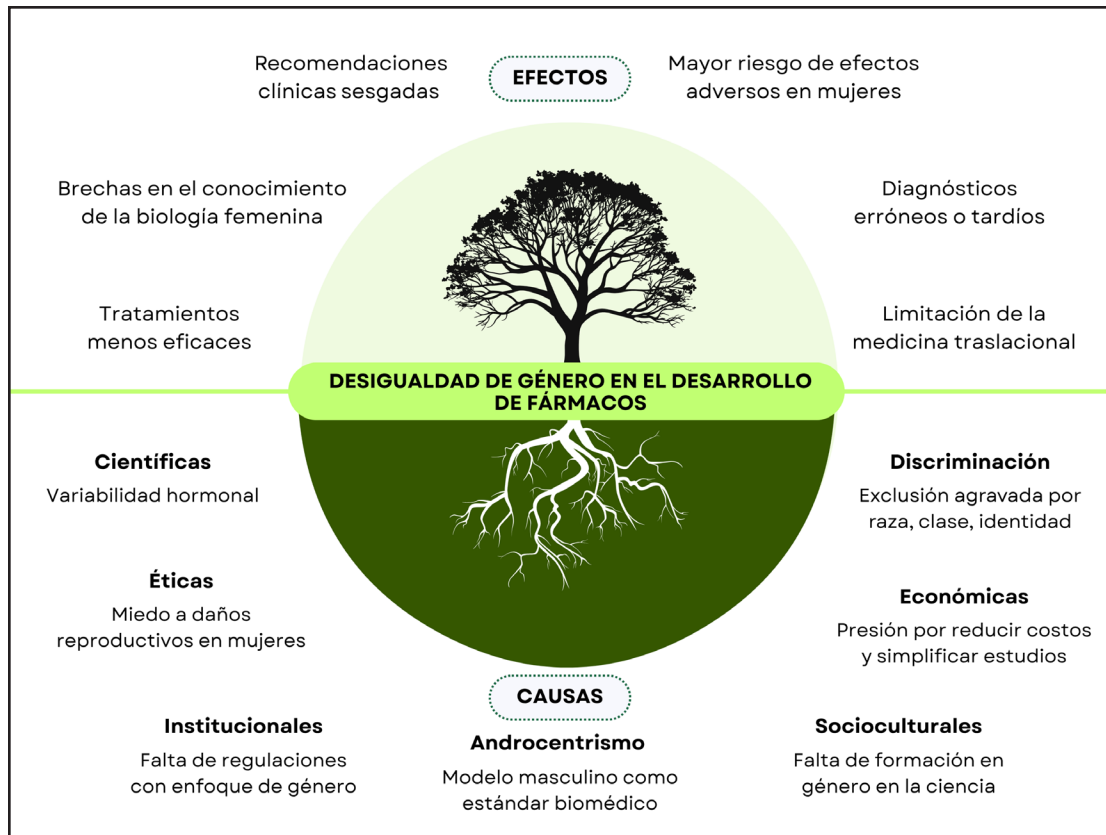
Este desequilibrio impulsó una visión de las mujeres centrada casi exclusivamente en lo reproductivo y hormonal y justificó su exclusión en numerosos protocolos de investigación. También, reforzó la idea de que necesitaban un control y regulación médica constante y contribuyó a la división sexual del trabajo: muchas tareas y responsabilidades quedaron reservadas a los hombres y las mujeres quedaron apartadas de numerosos espacios laborales y de toma de decisiones.

Así se afianzó un modelo biomédico androcéntrico, que condicionó no solo el diseño y la evaluación de fármacos, sino también el rumbo de investigaciones en múltiples áreas de la biomedicina. Para ver otros ejemplos de este sesgo en otras disciplinas, se pueden consultar los trabajos de autoras como Lu Ciccía, Cordelia Fine y Rebecca Jordan-Young en neurociencias, Evelyn Fox Keller y Sarah S. Richardson en biología moderna y genética, y Emily Martin que analiza los discursos sobre la fecundación y la reproducción humana.

La Figura 1 ilustra de manera integral las causas y efectos de la desigualdad de género en el desarrollo de fármacos, representando esta problemática como un árbol cuyas raíces simbolizan los factores estructurales que la originan y cuya copa refleja las consecuencias observables en la práctica biomédica. Entre las causas se incluyen los aspectos científicos, éticos, institucionales, económicos y el androcentrismo, previamente mencionados, a los que se suman la discriminación, que agrava la exclusión de grupos interseccionales como mujeres indígenas, racializadas o de bajos recursos, y los aspectos socioculturales, entre



Figura 1. Árbol invertido que representa las raíces estructurales de la desigualdad de género en el desarrollo de fármacos. Las raíces ilustran los factores que han contribuido históricamente a la exclusión de las mujeres en la investigación biomédica. Las ramas representan las consecuencias visibles de este sistema desigual.



Fuente: Saldívar y Murrieta, 2025.

los cuales se destaca la falta de formación con perspectiva de género en la ciencia, que perpetúa la falta de conciencia sobre esta problemática. Las repercusiones de estas causas en el diseño de fármacos y en su aplicación clínica, aspectos que serán analizados con mayor detalle en la siguiente sección.

Fármacos que han evidenciado la desigualdad de género

El sesgo de sexo y género descrito hasta ahora en la investigación biomédica ha condicionado en gran medida las preguntas de investigación que se formulan y las líneas de investigación que se priorizan, dentro de las cuales rara vez se ha

contemplado condiciones específicas de la salud de la mujer o de poblaciones marginadas. Esta falta de consideración, sumada a la limitada inclusión de variables de sexo y género en el diseño y la aplicación de terapias médicas, han afectado en la incidencia, la prevalencia y la evolución de ciertas enfermedades en este grupo poblacional. Además, ha repercutido en la seguridad y eficacia de los fármacos, aumentando el riesgo de reacciones adversas o de dosis inadecuadas para las mujeres.

La magnitud de este problema queda evidenciada por datos recientes. Un estudio del Instituto de Salud McKinsey (2024) reveló que, en los últimos 40 años, los medicamentos tienen 3,5 veces más probabilidades de ser retirados del mercado por causar efectos adversos en mujeres



que en hombres (McKinsey Health Institute, 2024). Además, se estima que el 80% de los fármacos retirados se deben a efectos secundarios en mujeres (Joshi, 2024).

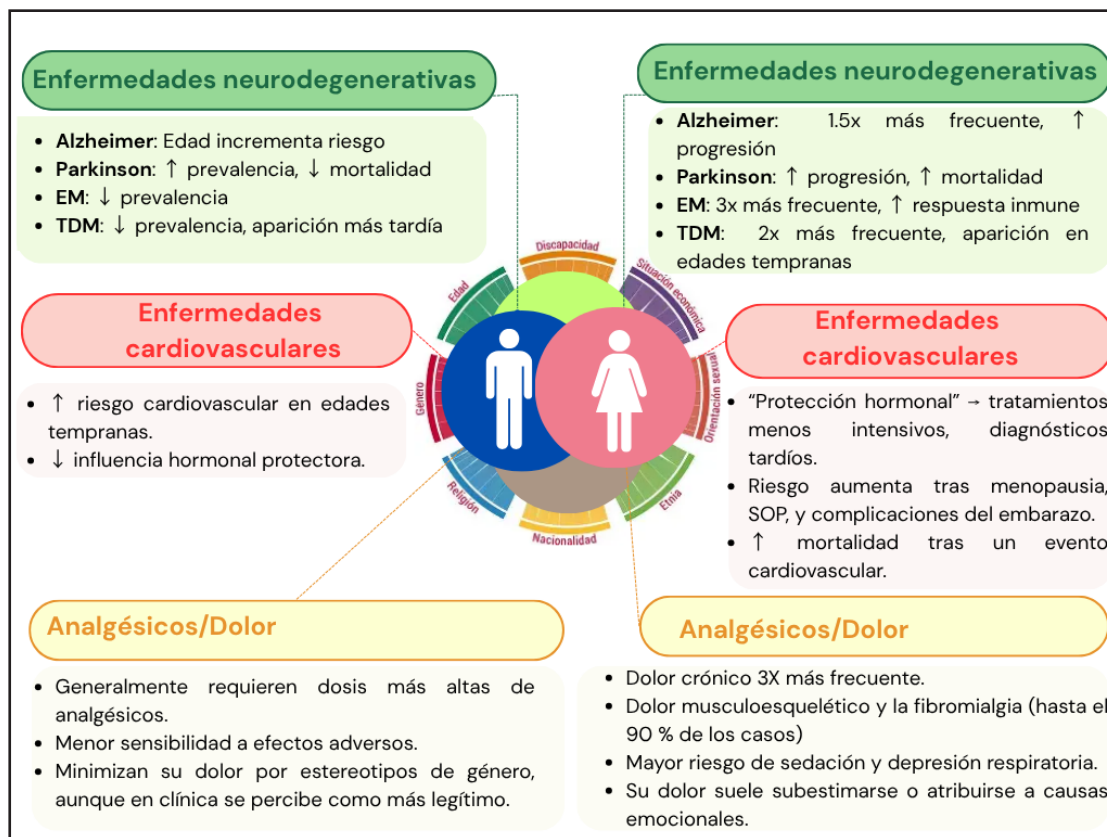
Para ilustrar cómo este sesgo ha afectado el desarrollo y la aplicación clínica de ciertos fármacos, a continuación, se presentan tres ejemplos concretos que evidencian desigualdades de género en el tratamiento de enfermedades cardiovasculares, enfermedades neurodegenerativas y en el tratamiento del dolor (Figura 2). Es importante aclarar que la distinción entre hombres y mujeres que suele presentarse en los estudios no busca reforzar una visión biologicista o dicotómica del cuerpo, sino que responde a una limitación de los datos disponibles. Hasta el momento, la

mayoría de la evidencia científica se ha recopilado de manera binaria, lo que impide reflejar la diversidad biológica y social real. Reconocer estas diferencias debe servir para visibilizar las brechas existentes y promover un enfoque más crítico, inclusivo e interseccional que tenga en cuenta cómo los factores biológicos, sociales y culturales se combinan y afectan la salud.

1. Enfermedades cardiovasculares

Las enfermedades cardiovasculares (ECV) constituyen una de las principales causas de muerte a nivel mundial tanto para hombres como mujeres; sin embargo, diversos estudios han demostrado que sus manifestaciones e impacto difieren de manera significativa entre ambos sexos (Gao et

Figura 2. Diferencias de sexo y género en la prevalencia, progresión y respuesta a fármacos en enfermedades neurodegenerativas, cardiovasculares y en el tratamiento del dolor. EM: esclerosis múltiple, TDM: trastorno depresivo mayor, SOP: Síndrome de ovario poliquístico.



Fuente: Saldivar y Murrieta, 2025.



al., 2019a; Betai *et al.*, 2024). Las mujeres suelen presentar una mayor mortalidad y peores pronósticos tras un evento cardiovascular, debido tanto a factores biológicos y fisiológicos como a determinantes socioculturales, entre los que se incluyen percepciones erróneas, diagnósticos tardíos y la aplicación de estrategias terapéuticas menos intensivas (DeFilippis and Van Spall, 2021).

La evidencia de que los estrógenos ejercen un efecto cardioprotector en las mujeres, especialmente antes de la menopausia (Iorga *et al.*, 2017) reforzó la percepción equivocada de que las mujeres estaban “protegidas” frente a las ECV en comparación con los hombres. Esta idea llevó a una subestimación de su riesgo real y a la implementación de tratamientos menos intensivos. Además, existen condiciones propias de la salud de la mujer que elevan el riesgo de ECV a lo largo de la vida. Entre ellas se encuentran la pérdida de protección hormonal tras la menopausia, el síndrome de ovario poliquístico, y complicaciones durante el embarazo como hipertensión gestacional, preeclampsia y diabetes gestacional, todas ellas con repercusiones tanto inmediatas como a largo plazo (Gao *et al.*, 2019b; Ryczkowska *et al.*, 2023).

Las diferencias también se observan en la manera en que mujeres y hombres responden a los medicamentos (Stolarz and Rusch, 2015). Aspectos como el peso, la edad, la cantidad de grasa corporal, la manera en que el hígado y los riñones funcionan, así como variaciones dependientes del sexo en las enzimas que metabolizan los fármacos, influyen en cómo estos se absorben, distribuyen y eliminan del organismo (Gandhi *et al.*, 2004).

En el caso de los medicamentos cardiovasculares, existen varios casos documentados (Tamargo *et al.*, 2017). Por ejemplo, las mujeres pueden presentar un mayor riesgo de sangrado al usar

anticoagulantes o trombolíticos, posiblemente relacionado con su menor tamaño corporal y con la presencia más frecuente de afecciones previas como hipertensión, diabetes o enfermedad renal. Además, en fármacos como la digoxina, usada para tratar ciertas enfermedades cardíacas, las mujeres suelen alcanzar concentraciones más altas en la sangre porque su cuerpo la distribuye y elimina más lentamente. También son más propensas a desarrollar hinchazón (edema) con antihipertensivos como la amlodipina y a experimentar presión arterial baja con betabloqueadores como el propranolol y el metoprolol. En este último caso, además, los anticonceptivos orales pueden aumentar su concentración en el organismo, incrementando el riesgo de efectos adversos.

2. Enfermedades neurodegenerativas

De forma similar, en las enfermedades neurodegenerativas, como el Alzheimer, el Parkinson y la esclerosis múltiple, así como algunos trastornos neuropsiquiátricos como el trastorno depresivo mayor, existen claras diferencias entre mujeres y hombres en su frecuencia, evolución y respuesta a los tratamientos médicos (Bianco, Antonacci and Liguori, 2023). Consciente de esta situación, desde el 2016 los Institutos Nacionales de Salud de Estados Unidos (NIH) exigen que los estudios en laboratorio y con animales tengan en cuenta las diferencias entre sexos para trasladar ese conocimiento a los ensayos clínicos con personas (Seney and Nestler, 2022).

A pesar de estas evidencias y nuevas regulaciones, muchos tratamientos continúan desarrollándose sin una adecuada consideración de estas diferencias. Un ejemplo es el fármaco lecanemab, aprobado en 2023 para el tratamiento del Alzheimer. Los análisis indican que su beneficio es mayor en hombres que en mujeres, hecho particularmente preocupante considerando



que cerca de dos tercios de los pacientes con Alzheimer son mujeres (Andrews *et al.*, 2025).

En la enfermedad de Parkinson, aunque hay más casos en hombres, las mujeres suelen tener una evolución más rápida, mayor discapacidad motora y un riesgo de muerte más alto. Además, fármacos como levodopa y tolcapona provocan efectos secundarios más intensos en mujeres (Bianco, Antonacci and Liguori, 2023).

En la esclerosis múltiple, las mujeres tienen alrededor de tres veces más probabilidad de padecerla y suelen presentar la enfermedad a edades más tempranas, mientras que los hombres tienden a desarrollar formas más agresivas y con peor pronóstico a largo plazo (Coyle, 2021). Aunque aún son limitados los estudios que analizan en detalle las diferencias en las respuestas a los tratamientos, se ha observado que las mujeres tratadas con interferón beta (IFN β) también suelen progresar más lento que los hombres (Bianco, Antonacci and Liguori, 2023).

En el trastorno depresivo mayor, además de afectar el estado de ánimo y la vida cotidiana, la enfermedad puede causar con el tiempo daños neurológicos severos. Aquí, la prevalencia en mujeres es casi el doble que en los hombres, una diferencia que no se explica únicamente por factores biológicos, sino también por desigualdades sociales y culturales. En este contexto, investigaciones recientes, como las de la Dra. Ávila-Rieger, buscan comprender cómo desigualdades acumuladas desde edades tempranas, como el menor acceso a la educación, mayores niveles de estrés y menos oportunidades económicas y laborales, se relacionan con las diferencias observadas en la clínica, y cómo estas condiciones terminan afectando la salud física y cerebral y aumentando el riesgo de deterioro cognitivo en mujeres y poblaciones racializadas (Avila *et al.*, 2019).

Aunque aún queda mucho trabajo por hacer, estos estudios pueden transformar nuestra comprensión de la salud y su relación con factores ambientales y sociales. Visibilizar estas desigualdades y sus efectos en la salud cuestiona varios supuestos científicos y abre paso a una investigación más sensible al contexto social.

3. Tratamiento del dolor

El tratamiento del dolor presenta retos considerables, ya que su experiencia no depende únicamente de la lesión, sino también del significado que esta adquiere para cada persona. Se trata de un fenómeno complejo y multidimensional en el que interactúan factores biológicos, psicológicos y sociales. A esta complejidad se añaden los determinantes de sexo y género, que influyen de manera decisiva en cómo el dolor es reconocido, evaluado y tratado en la práctica clínica.

Con frecuencia, el dolor que presentan las mujeres es minimizado o atribuido a causas emocionales, lo que conduce a diagnósticos tardíos y a tratamientos insuficientes (Templeton, 2020). En este contexto, es más común que se les prescriban antidepresivos o intervenciones psicológicas en lugar de analgésicos adecuados, perpetuando una atención insuficiente y aumentando la carga de sufrimiento (Morgan *et al.*, 2024).

Además, las mujeres se ven afectadas de manera desproporcionada por condiciones de dolor crónico: lo padecen con mayor frecuencia, intensidad y en más localizaciones corporales que los hombres (Osborne and Davis, 2022). Entre las condiciones más comunes destacan la migraña (2 a 3 veces más frecuente en mujeres), el dolor musculoesquelético y la fibromialgia (hasta el 90% de los casos se diagnostican en mujeres), el dolor abdominal y el síndrome de intestino irritable (1.5 a 3 veces más frecuentes en mujeres),



así como el dolor ginecológico y obstétrico, incluyendo dismenorrea, endometriosis y dolor pélvico persistente durante el embarazo y el posparto (Osborne and Davis, 2022).

En cuanto a la respuesta a los medicamentos, está documentado que las mujeres suelen requerir entre un 30 y un 40% menos dosis de opioides para obtener el mismo alivio analgésico, efecto atribuido a la modulación estrogénica de las vías del dolor y de los receptores opioides (Whitley, 2009). Además, se han observado diferencias dependientes del sexo en la eficacia y en los efectos adversos de analgésicos como el ibuprofeno y el paracetamol, vinculadas a variaciones en el metabolismo de los fármacos (Mezzalana and Toffoli, 2021).

En 2024, la Asociación Internacional para el Estudio del Dolor (IASP, por sus siglas en inglés) lanzó una campaña global destinada a visibilizar las disparidades de sexo y género en el dolor, incluyendo el abordaje de poblaciones transgénero (Boerner, Lorello and Nabbijohn, 2024). Esta iniciativa busca sensibilizar a la comunidad científica y clínica, así como impulsar la actualización de guías y recomendaciones internacionales, incorporando de manera explícita la perspectiva de sexo y género en la evaluación y el tratamiento del dolor.

Sesgos en los datos y el diseño de fármacos basado en IA

A partir de lo expuesto, resulta evidente la necesidad de incorporar estrategias que aborden las diferencias biológicas, sociales y culturales con el fin de diseñar fármacos más eficaces y seguros para todas las poblaciones. En este sentido, la IA promete revolucionar este proceso aprendiendo de grandes conjuntos de datos para predecir la eficacia, la toxicidad y otras propiedades de los

fármacos. Entre sus mayores promesas se encuentra la medicina personalizada, que aspira a adaptar tratamientos y terapias a las características individuales de cada paciente.

No obstante, esta visión enfrenta un obstáculo fundamental: los modelos actuales de IA se construyen y entrenan a partir de datos que no siempre son completos ni representativos y, en muchos casos, tampoco incluyen variables biológicas, sociales o ambientales que podrían ayudar a explicar las diferencias en la respuesta a los fármacos. Esta omisión limita la capacidad de los algoritmos para generar predicciones viables y realmente equitativas. De hecho, diversos estudios han mostrado que los sesgos presentes en los datos de origen se trasladan directamente a los modelos computacionales que se diseñan hoy en día y en sus predicciones (Cirillo *et al.*, 2020).

Un ejemplo claro de las consecuencias de la subrepresentación de mujeres en los datos con los que se entrenan modelos de IA se observa en aquellos generados para evaluar riesgo cardiovascular (Sau *et al.*, 2025). Estos modelos muestran un menor rendimiento en mujeres, es decir, son menos precisos al predecir su riesgo real: tienden a cometer más errores de clasificación, subestiman los casos de alto riesgo y, en consecuencia, pueden retrasar los diagnósticos y limitar el acceso a intervenciones oportunas. Además, existe el riesgo de que los algoritmos clasifiquen a estos grupos históricamente marginados como “atípicos” en comparación con los estándares biomédicos dominantes, perpetuando así inequidades en la atención médica (Lau, 2025).

La selección de variables es otro punto clave en el ciclo de vida de un modelo basado en IA, en esta etapa se decide sobre qué características o factores se incluyen para entrenar el algoritmo y orientar sus predicciones. Esta etapa es crítica



porque define qué aspectos de la realidad son representados y cuáles quedan fuera. Cuando se eligen indicadores inadecuados, los algoritmos pueden reproducir y amplificar desigualdades. Un ejemplo de esto lo describe Obermeyer y colegas, quienes demostraron que el uso del costo de atención médica como indicador de enfermedad introdujo sesgos raciales, subestimando las necesidades de atención de pacientes racializados debido a la inversión históricamente menor en su cuidado (Obermeyer *et al.*, 2019). De forma similar, algunos modelos de predicción de riesgo por COVID-19 han mostrado sesgos al no incorporar adecuadamente los determinantes sociales de la salud, lo que distorsiona los resultados para poblaciones vulnerables (Chung *et al.*, 2021).

La inclusión del “sexo” como variable también plantea dilemas. Goodman y colaboradoras advierten que, cuando se emplea como criterio de decisión o de exclusión en lugar de como un factor explicativo, puede perpetuar e incluso intensificar la discriminación (Goodman *et al.*, 2025). Un ejemplo que plantean es el de los algoritmos que predicen resultados adversos tras un bypass coronario. Estos proyectan peores desenlaces en mujeres no por diferencias biológicas inmodificables, sino porque los datos reflejan una atención históricamente desigual, con diagnósticos más tardíos y menor acceso a intervenciones de calidad. Como resultado, tienden a recomendar con mayor frecuencia evitar una intervención temprana en mujeres, lo que en la práctica penaliza su acceso al tratamiento. Este tipo de situaciones despierta serias preocupaciones en términos de equidad, pues el sexo deja de ser una variable para comprender diferencias clínicas y se convierte en un obstáculo para la atención médica.

Estas situaciones demuestran que los algoritmos no son neutrales y es fundamental diseñarlos de manera que garanticen la transparencia y la

interpretabilidad de sus predicciones, evitando al mismo tiempo los modelos de clasificación binarios que reducen la diversidad humana a solo dos categorías, hombres y mujeres. Esta simplificación invisibiliza a las personas trans y no binarias en la investigación médica y limita su acceso a diagnósticos y tratamientos adecuados. El problema, en consecuencia, no radica únicamente en los datos, sino también en la forma en que los algoritmos son concebidos, al tender a simplificar en exceso la diversidad humana.

Otro punto fundamental en la vida útil de un modelo de IA es su validación. Esto implica comprobar que funciona bien no solo con los datos con los que se entrenó, sino también con datos distintos que permitan monitorear su impacto real. Este proceso incluye vigilar continuamente posibles sesgos o degradaciones de su rendimiento para asegurar que siga siendo confiable, útil y equitativo en situaciones reales. En este sentido, aún no existe uniformidad en las métricas utilizadas para evaluar su desempeño en entornos clínicos (Cabanillas Silva *et al.*, 2024). De igual forma, indicadores como las tasas de infra diagnóstico o sobrediagnóstico no bastan para saber si un modelo es realmente imparcial. Además, medir la “justicia” no es sencillo, porque requiere entender tanto el contexto de la atención médica como las experiencias de distintas poblaciones. Por último, también resulta difícil equilibrar justicia y precisión. Mejorar el desempeño del modelo en grupos históricamente desfavorecidos puede implicar pequeñas reducciones en su exactitud global.

En la etapa final donde los profesionales de la salud interpretan y aplican las salidas de estos modelos también pueden producirse sesgos. Estos surgen, por un lado, de la falta de explicabilidad de los modelos, es decir, que el modelo no muestre claramente cómo llegó a su recomendación, dificulta detectar y corregir



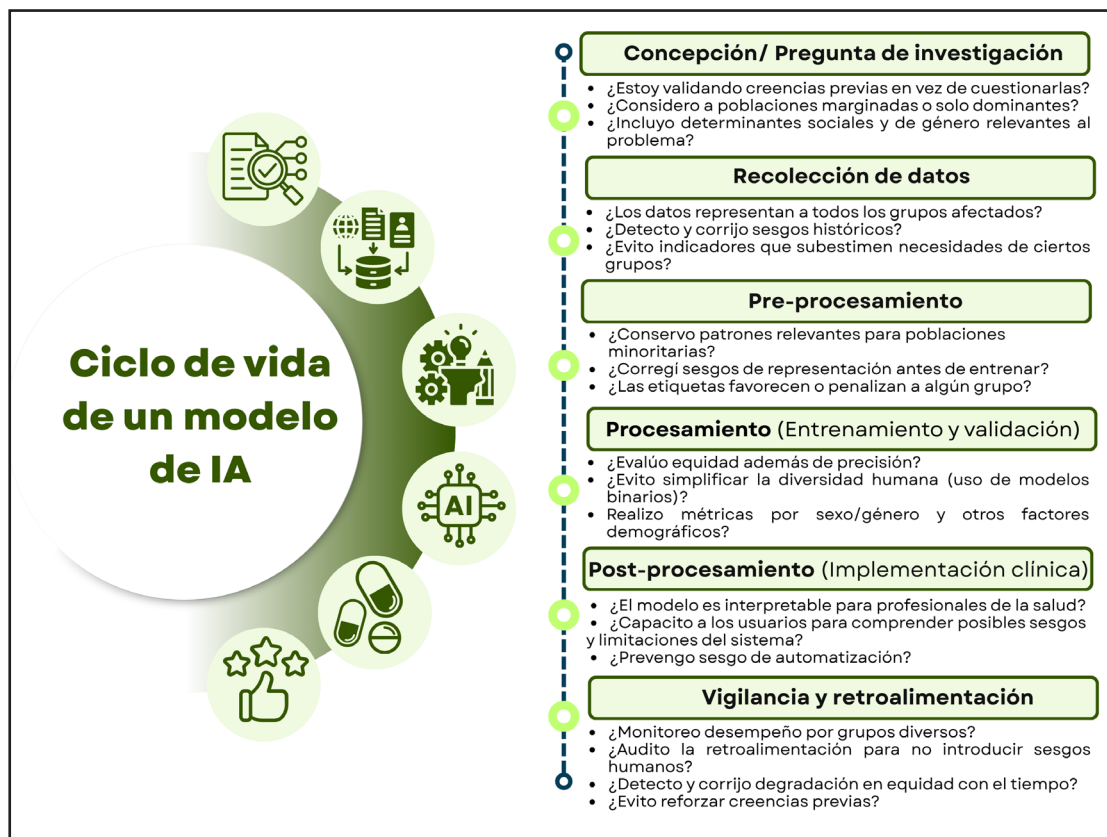
sesgos que ya venían incorporados. Por otro lado, la falta de capacitación de los usuarios para entender cómo funciona el modelo puede llevar a introducir errores. Entre los principales riesgos están el sesgo de automatización, que hace que se confíe demasiado en el sistema (omitiendo fallos o siguiendo recomendaciones erróneas); el sesgo de confirmación, que lleva a interpretar los resultados de forma que refuercen creencias previas; y la fatiga de alertas, en la que un exceso de avisos falsos positivos provoca desconfianza y que la herramienta se use menos. Además, cuando los usuarios corrigen o alimentan manualmente el sistema sin la supervisión adecuada, pueden introducir errores humanos o cognitivos en los datos de aprendizaje, perpetuando problemas en lugar de resolverlos.

Aplicaciones de la IA para mitigar el sesgo de género

Para revertir las consecuencias de la histórica exclusión de mujeres y otras poblaciones marginadas en la investigación biomédica, resulta fundamental abordar las causas profundas de estas desigualdades, que claramente trascienden el ámbito tecnológico. No obstante, las iniciativas basadas en IA constituyen un primer paso para visibilizar estas inequidades y para orientar sobre qué datos deben recopilarse y cómo diseñar futuros modelos de IA.

En este sentido, la Figura 3 presenta un conjunto de preguntas prácticas para cada etapa del ciclo de vida de un modelo de IA, que pueden servir

Figura 3. Preguntas clave para reducir sesgos de género durante el ciclo de vida de un modelo de IA..



Fuente: Saldívar y Murrieta, 2025.



como guía para identificar y mitigar sesgos de género. Por ejemplo, se enfatiza la importancia de una reflexión crítica desde la formulación de la pregunta de investigación, evitando la validación acrítica de creencias previas y considerando la diversidad de las poblaciones involucradas. Para avanzar y promover una ciencia más rigurosa y con perspectiva de género es esencial integrar la equidad desde los modelos, mediante equipos diversos y preguntas de investigación sensibles al sexo y al género (Hasanzadeh *et al.*, 2025). Asimismo, se resalta la necesidad de garantizar la representatividad de los datos y corregir posibles sesgos históricos o de muestreo antes del entrenamiento del modelo. Durante el procesamiento, se propone evaluar la equidad junto con la precisión, evitando simplificaciones que reduzcan la complejidad de la diversidad humana. Finalmente, en las etapas de implementación y seguimiento, se destaca la relevancia de promover la interpretabilidad del modelo, capacitar a los usuarios para reconocer sesgos y limitaciones, y establecer mecanismos de monitoreo continuo que permitan detectar degradaciones en la equidad y prevenir la reproducción de estereotipos o desigualdades de género a lo largo del tiempo.

En la práctica, algunas de estas preguntas han llevado a distintas acciones y avances, entre ellos se encuentran:

- Mejorar la representatividad de los datos: por ejemplo, mediante técnicas de aumento de datos en imágenes médicas (Wang *et al.*, 2024) o con algoritmos como AwareDX, que equilibran la información sobre efectos adversos entre hombres y mujeres (Chandak and Tatonetti, 2020).
- Diseñar y ajustar algoritmos más justos, un ejemplo es D-BIAS que permite encontrar y corregir sesgos en los datos, proponiendo

ajustes para que los resultados sean más justos e incorporen criterios explícitos de equidad en su desarrollo (Ghai and Mueller, 2022).

- Validar los resultados en contextos diversos, para esto se pueden utilizar métricas sensibles al contexto social y calibrar los modelos para que sus predicciones se parezcan más a la realidad y no subestimen diagnósticos en mujeres (Chandak and Tatonetti, 2020; Cabanillas Silva *et al.*, 2024).
- Impulsar herramientas de código abierto como las librerías de IBM (Bellamy *et al.*, 2018) o Aequitas (Saleiro *et al.*, 2019) y marcos éticos como FAIRS que orienten a quienes diseñan y aplican IA en salud (Goodman *et al.*, 2025).
- Fomentar la participación de mujeres y grupos subrepresentados en ciencia de datos, a través de redes y programas que fortalezcan el vínculo entre innovación tecnológica y equidad de género.

La Tabla 1 resume estas aplicaciones de la IA para reducir desigualdades de género en el diseño de fármacos y en la medicina biomédica, destacando las principales áreas de aplicación y la forma en que cada iniciativa contribuye a diagnósticos y tratamientos más justos y eficaces.

Conclusiones

La evidencia presentada en este artículo muestra que los sesgos de sexo y género en la investigación biomédica no son simples “errores metodológicos”, sino el resultado de decisiones históricas y estructuras sociales que han privilegiado al cuerpo masculino como modelo de referencia. Las diferencias observadas en la incidencia, prevalencia o evolución de ciertas enfermedades entre distintos grupos poblacionales no deben interpretarse desde una perspectiva esencialista



Tabla 1. Aplicaciones orientadas a reducir los sesgos de género en la IA y el diseño de fármacos.

Área de aplicación	Ejemplo / Herramienta	Qué hace	Referencia
Datos representativos	Aumento de datos en imágenes médicas	Crea versiones adicionales de radiografías o resonancias para incluir más mujeres en los datos. Reduce los errores de clasificación por género hasta en un 30 %, contribuyendo a diagnósticos más precisos.	Wang et al., 2024.
	AwareDX	Revisa 50 años de reportes de efectos adversos y crea subconjuntos equilibrados de datos entre hombres y mujeres, dando información más segura para las pacientes.	Chandak and Tatonetti, 2020.
Algoritmos justos	Liga de Justicia Algorítmica (“Sombras de Género”)	Detectó errores en sistemas de reconocimiento facial que confundían más a mujeres; logró que empresas mejoraran sus bases de datos y redujo los errores de identificación hasta en un 30%.	Raji and Buolamwini, 2022.
	D-BIAS	Herramienta interactiva que permite encontrar y corregir sesgos en los datos, proponiendo ajustes para que los resultados sean más justos.	Ghai and Mueller, 2022.
Validación/ Métricas	Calibración de modelos	Ajusta los algoritmos para que sus predicciones se parezcan más a la realidad y no subestimen diagnósticos en mujeres.	Cabanillas Silva et al., 2024.
	Ratios de paridad demográfica y probabilidades igualadas	Miden si los algoritmos son más justos entre grupos y pueden reducir hasta un 79% las desigualdades de género en los datos.	Chandak and Tatonetti, 2020.
	Análisis de la Curva de Decisión (DCA)	Mejora modelos predictivos en cáncer cervicouterino, adaptándolos a distintas poblaciones en lugar de usar un enfoque único.	Tisler et al., 2024.
	Indicadores de injusticia en modelos de lenguaje clínicos	Evalúan si los textos médicos generados por IA tienen sesgos que podrían llevar a diagnósticos erróneos por género.	Chen et al., 2025.
Herramientas abiertas	Librerías de IBM para Python	Programas gratuitos para detectar y corregir sesgos en datos y algoritmos.	Bellamy et al., 2018.
	Aequitas (Univ. de Chicago)	Audita sesgos en IA para ayudar en decisiones de políticas públicas y salud	Saleiro et al., 2019.
Marcos éticos y sociales	FAIRS Framework	Serie de preguntas para saber si incluir sexo/género en un algoritmo es útil o injusto, considerando contexto y daños sociales.	Goodman et al., 2025
	Mujeres en la Ciencia de Datos (WiDS)	Red mundial que organiza talleres, mentorías y “datatones” para aumentar la participación femenina en ciencia de datos.	Anon, n.d.

Fuente: Elaboración propia, 2025.



o dicotómica del cuerpo. Por el contrario, ponen de relieve la necesidad de reconocer la diversidad biológica de manera crítica e interseccional y de cuestionar la construcción histórica del modelo dominante. Este enfoque es fundamental para cerrar vacíos en el conocimiento, reducir los riesgos a los que está expuesta gran parte de la población y avanzar hacia una ciencia más justa y equitativa.

Del mismo modo, con el análisis de algunas aplicaciones clínicas de la IA se evidenció que si los modelos de IA no consideran variables biológicas, sociales y ambientales relacionadas con el desarrollo de las enfermedades existe un alto riesgo de que amplifiquen las desigualdades existentes. Por ello, no basta con corregir los resultados algorítmicos: es necesario abordar las causas profundas de estas desigualdades.

En cuanto a las propuestas computacionales, las iniciativas están orientadas en mejorar la representatividad de los datos, replantear los indicadores y supuestos que guían los modelos de IA y aplicar mecanismos de auditoría más transparentes que garanticen predicciones confiables y equitativas.

Asimismo, resulta imprescindible incorporar la perspectiva de género e interseccionalidad desde las fases preclínicas. Solo así se generarán datos sólidos que puedan trasladarse de manera efectiva a la atención clínica mediante la medicina traslacional, impulsando el desarrollo de nuevos tratamientos más seguros y eficaces.

Referencias Bibliográficas

- ALLEGRA, S. et al. (2023). Evaluation of Sex Differences in Preclinical Pharmacology Research: How Far Is Left to Go? In: *Pharmaceuticals*, Vol 16(6): 786.
- ANDREWS, D. et al. (2025). The higher benefit of lecanemab in males compared to females in CLARITY AD is probably due to a real sex effect. In: *Alzheimer's and Dementia*, Vol 21(1): e14467.
- AVILA, J.F. et al. (2019). Sex/gender differences in cognitive trajectories vary as a function of race/ethnicity. In: *Alzheimer's and Dementia*, Vol 15(12):1516–1523.
- BELLAMY, R.K.E. et al. (2018). AI Fairness 360: An Extensible Toolkit for Detecting, Understanding, and Mitigating Unwanted Algorithmic Bias. In: *IBM Journal of Research and Development*, Vol 63(4/5):4:1-4:15.
- BETAI, D. et al. (2024) Gender Disparities in Cardiovascular Disease and Their Management: A Review. In: *Cureus*, Vol 16(5):e59663.
- BIANCO, A., ANTONACCI, Y. and LIGUORI, M. (2023). Sex and Gender Differences in Neurodegenerative Diseases: Challenges for Therapeutic Opportunities. In: *International Journal of Molecular Sciences*, Vol 24(7):6354.
- BOERNER, K.E., LORELLO, G. and NABBIJOHN, A.N. (2024). Pain and Gender Diversity – Beyond the Binary. [Online] Available in: <https://www.iasp-pain.org/resources/fact-sheets/pain-and-gender-diversity-beyond-the-binary/>
- CABANILLAS SILVA, P. et al. (2024). Evaluating gender bias in ML-based clinical risk prediction models: A study on multiple use cases at different hospitals. In: *Journal of Biomedical Informatics*, Vol 157:104692.



- CHANDAK, P. and TATONETTI, N.P. (2020). Using Machine Learning to Identify Adverse Drug Effects Posing Increased Risk to Women. In: *Patterns*, Vol 1(7):100108.
- CHEN, X. et al. (2025). Evaluating and mitigating bias in AI-based medical text generation. In: *Nature Computational Science*, Vol 5(5):388–396.
- CHUNG, H. et al. (2021). Gender Bias in Artificial Intelligence: Severity Prediction at an Early Stage of COVID-19. In: *Frontiers in Physiology*, Vol 12:778720.
- CICCIA, L. (2022). *La invención de los sexos: Cómo la ciencia puso el binarismo en nuestros cerebros y cómo los feminismos pueden ayudarnos a salir de ahí*. 1st ed. Ciudad de México: Siglo XXI editores.
- COYLE, P.K. (2021). What can we learn from sex differences in MS? In: *Journal of Personalized Medicine*, Vol 11(10):1006.
- DEFILIPPIS, E.M. and VAN SPALL, H.G.C. (2021). Is it Time for Sex-Specific Guidelines for Cardiovascular Disease? In: *Journal of the American College of Cardiology*, Vol 78(2):189–192.
- FAUSTO-STERLING ANNE (2000). *Sexing the Body*. 1st ed. New York: Basic Books.
- GANDHI, M. et al. (2004). Sex Differences in Pharmacokinetics and Pharmacodynamics. In: *Annual Review of Pharmacology and Toxicology*, Vol 44:499-523.
- GAO, Z. et al. (2019). Gender differences in cardiovascular disease. In: *Medicine in Novel Technology and Devices*, Vol 4: 100025.
- GHAI, B. and MUELLER, K. (2022). D-BIAS: A Causality-Based Human-in-the-Loop System for Tackling Algorithmic Bias. In: *IEEE Trans Vis Comput Graph*, Vol 29(1):473-482.
- GOODMAN, K.E. et al. (2025). FAIRS-A Framework for Evaluating the Inclusion of Sex in Clinical Algorithms. In: *New England Journal of Medicine*, Vol 392(4):404-41.
- HASANZADEH, F. et al. (2025). Bias recognition and mitigation strategies in artificial intelligence healthcare applications. In: *Digital Medicine*, Vol 8:154.
- IORGA, A. et al. (2017). The protective role of estrogen and estrogen receptors in cardiovascular disease and the controversial use of estrogen therapy. In: *Biology of sex differences*, Vol 8(1):33.
- JOSHI, A. (2024). Big data and AI for gender equality in health: bias is a big challenge. In: *Frontiers in Big Data*, Vol 7:1436019.
- LAU, P.L. (2025). Rewriting the Narrative of AI Bias: A Data Feminist Critique of Algorithmic Inequalities in Healthcare. In: *Law, Technology and Humans*, Vol 7 (2): 8-26.
- LIU, K.A. and DIPIETRO MAGER, N.A. (2016). Women's involvement in clinical trials: Historical perspective and future implications. In: *Pharmacy Practice*, Vol 14(1):708.
- MCKINSEY HEALTH INSTITUTE (2024). Closing the women's health gap: A \$1 trillion opportunity to improve lives and economies. [Online] Available in: <https://www.mckinsey.com/mhi/our-insights/closing-the-womens-health-gap-a-1-trillion-dollar-opportunity-to-improve-lives-and-economies>
- MEZZALIRA, S. and TOFFOLI, G. (2021). The effects of sex on pharmacogenetically guided drug treatment. In: *Pharmacogenomics*, Vol 22(15):959-962.



- MORGAN, J. et al. (2024). Sex and gender differences in pain perception and management in clinical settings. In: *All Life*, Vol 17(1): 236742.
- OBERMEYER, Z. et al. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. In: *Science*, Vol 366(6464):447-453.
- OSBORNE, N.R. and DAVIS, K.D. (2022). Sex and gender differences in pain. In: *International Review of Neurobiology*. Academic Press Inc., Vol 164:277-307.
- OUDSHOORN NELLY (1997). La mujer hormonal, creación de un concepto. En: *Ciencias*, Vol 48: 20–26.
- RAJI, I.D. and BUOLAMWINI, J. (2022). Actionable Auditing Revisited: - Investigating the Impact of Publicly Naming Biased Performance Results of Commercial AI Products. In: *Communications of the ACM*, Vol 66(1):101–108.
- RYCZKOWSKA, K. et al. (2023). Menopause and women's cardiovascular health: is it really an obvious relationship? In: *Archives of Medical Science*, Vol 19(2): 458–466.
- SALDIVAR-GONZÁLEZ, FI. et al. (2023). Inteligencia artificial en el diseño de fármacos: hacia la inteligencia aumentada. En: *Educación Química*. Vol 34(2): 17-25.
- SALEIRO, P. et al. (2019). Aequitas: A Bias and Fairness Audit Toolkit. [Online] Available from: <http://arxiv.org/abs/1811.05577>.
- SAU, A. et al. (2025). Artificial intelligence-enhanced electrocardiography for the identification of a sex-related cardiovascular risk continuum: a retrospective cohort study. In: *The Lancet Digital Health*, Vol 7(3):e184–e194.
- SENEY, M.L. and NESTLER, E.J. (2022). Introduction to Special Issue: Insight Into Sex Differences in Neuropsychiatric Syndromes From Transcriptomic Analyses. In: *Biological Psychiatry*, Vol 91(1):3-5.
- STOLARZ, A.J. and RUSCH, N.J. (2015). Gender differences in cardiovascular drugs. In: *Cardiovascular Drugs and Therapy*, Vol 29(4):403–410.
- TAMARGO, J. et al. (2017). Gender differences in the effects of cardiovascular drugs. In: *European Heart Journal - Cardiovascular Pharmacotherapy*, Vol 3(3):163-182.
- TEMPLETON, K.J. (2020). Sex and Gender Issues in Pain Management. In: *Journal of Bone and Joint Surgery*, Vol 102 Suppl 1:32-35.
- TISLER, A. et al. (2024). Nationwide study on development and validation of a risk prediction model for CIN3+ and cervical cancer in Estonia. In: *Scientific Reports*, 14(1): 24589.
- WANG, R. et al. (2024). Drop the shortcuts: image augmentation improves fairness and decreases AI detection of race and other demographics from medical images. In: *eBioMedicine*, Vol 102:105047.
- WHITLEY, H.P. (2009). Sex-Based Differences in Drug Activity. In: *American Family Physician*, Vol 80(11):1254-8.
- WiDS Worldwide. [Online] Available in: <https://www.widsworldwide.org>.
- YOON, D.Y. et al. (2014). Sex bias exists in basic science and translational surgical research. In: *Surgery*, Vol 156(3): 508–516.

