

Artículo Científico

Estrategias de diversidad e inclusión en procesos de reclutamiento asistidos por IA

Diversity and inclusion strategies in AI-assisted recruitment processes



Jara-Álvarez, Gonzalo Xavier ¹



<https://orcid.org/0009-0003-5151-8432>



gonzalo.jara.alvarez@utelvt.edu.ec



Universidad Técnica Luis Vargas Torres de Esmeraldas, Ecuador, La Concordia.



Salgado-Ortiz, Patricia Janella ²



<https://orcid.org/0000-0002-5366-7330>



patricia.salgado@utelvt.edu.ec



Universidad Técnica Luis Vargas Torres de Esmeraldas, Ecuador, La Concordia.



Santander-Salmon, Erika Stephania ³



<https://orcid.org/0000-0003-3279-5250>



erika.santander@utelvt.edu.ec



Universidad Técnica Luis Vargas Torres de Esmeraldas, Ecuador, La Concordia.



Quiñonez-Cabeza, Betty Maribel ⁴



<https://orcid.org/0000-0002-3964-2153>



betty.quinonez@utelvt.edu.ec



Universidad Técnica Luis Vargas Torres de Esmeraldas, Ecuador, La Concordia.

Autor de correspondencia ¹



DOI / URL: <https://doi.org/10.55813/gaea/rcym/v2/n4/53>

Resumen: El estudio explora críticamente el impacto de la inteligencia artificial en los procesos de reclutamiento, centrándose en su capacidad para reproducir sesgos históricos que afectan la diversidad laboral. Mediante una revisión bibliográfica de investigaciones y documentos normativos entre 2013 y 2024, se identificaron estrategias orientadas a mitigar el sesgo algorítmico, incluyendo auditorías de equidad, uso de datos balanceados, técnicas de desbiado y formación de equipos multidisciplinares. Los hallazgos revelan que ninguna medida aislada resulta suficiente y que el despliegue efectivo requiere combinar prácticas técnicas y marcos organizacionales comprometidos con la transparencia y la equidad. Se concluye que la adopción responsable de IA en reclutamiento depende de articular innovación tecnológica con principios éticos sólidos, enfatizando la necesidad de políticas inclusivas, procesos auditables y la integración de perspectivas diversas para garantizar oportunidades equitativas en la selección de talento.

Palabras clave: inteligencia artificial; reclutamiento inclusivo; sesgo algorítmico; auditoría de equidad; diversidad laboral.



Check for updates

Received: 15/Nov/2024

Accepted: 02/Dic/2024

Published: 29/Dic/2024

Cita: Jara-Álvarez, G. X., Salgado-Ortiz, P. J., Santander-Salmon, E. S., & Quiñonez-Cabeza, B. M. (2024). Estrategias de diversidad e inclusión en procesos de reclutamiento asistidos por IA. *Revista Científica Ciencia Y Método*, 2(4), 50-62. <https://doi.org/10.55813/gaea/rcym/v2/n4/53>

Revista Científica Ciencia y Método (RCyM)
<https://revistacym.com>
revistacym@editorialgrupo-aea.com
info@editorialgrupo-aea.com

© 2024. Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional**.



Abstract:

The study critically explores the impact of artificial intelligence on recruitment processes, focusing on its ability to reproduce historical biases that affect employment diversity. Through a literature review of research and policy documents between 2013 and 2024, strategies aimed at mitigating algorithmic bias were identified, including fairness audits, use of balanced data, de-biasing techniques, and multidisciplinary team building. The findings reveal that no single measure is sufficient and that effective deployment requires a combination of technical practices and organizational frameworks committed to transparency and equity. It is concluded that the responsible adoption of AI in recruitment depends on articulating technological innovation with sound ethical principles, emphasizing the need for inclusive policies, auditable processes and the integration of diverse perspectives to ensure equitable opportunities in talent selection.

Keywords: artificial intelligence; inclusive recruitment; algorithmic bias; equity auditing; workforce diversity.

1. Introducción

La creciente incorporación de sistemas de inteligencia artificial (IA) en los procesos de reclutamiento representa uno de los cambios más significativos en la gestión del talento humano de las últimas décadas. Estas tecnologías prometen optimizar la identificación y selección de candidatos mediante algoritmos de aprendizaje automático y procesamiento de lenguaje natural que permiten filtrar grandes volúmenes de datos en tiempos reducidos (van Esch et al., 2019). No obstante, esta evolución tecnológica plantea interrogantes sustanciales sobre su impacto en la promoción de la diversidad y la inclusión laboral, dado que múltiples investigaciones han evidenciado que los sistemas de IA, al ser entrenados con datos históricos, pueden perpetuar o incluso amplificar sesgos discriminatorios preexistentes en las organizaciones (Raghavan et al., 2020). El problema central radica en la tensión entre la eficiencia que aportan estas herramientas y su potencial para reproducir patrones de exclusión, limitando el acceso equitativo de grupos tradicionalmente subrepresentados, tales como mujeres, personas con discapacidades o minorías étnicas, a oportunidades laborales de calidad (Bogen & Rieke, 2018).

Diversos factores contribuyen a la persistencia de este problema. Entre los más relevantes se encuentran el sesgo algorítmico, derivado de datos de entrenamiento no balanceados, y la opacidad de los modelos predictivos empleados, que dificultan la auditoría y la explicación de las decisiones de selección (Mehrabi et al., 2021). Asimismo, la falta de regulaciones específicas y de marcos de gobernanza que orienten el uso ético de la IA en recursos humanos agrava la situación, generando un entorno de incertidumbre normativa y de escasa rendición de cuentas (Kim, 2022).

Estas afectaciones tienen consecuencias directas sobre la cohesión organizacional, la percepción de justicia procedimental entre los postulantes y la reputación corporativa, factores que inciden de manera crítica en la sostenibilidad de las estrategias de talento a largo plazo (Calvard & Jeske, 2018).

La relevancia de estudiar este fenómeno estriba en su implicancia no solo para la eficacia de los procesos de reclutamiento, sino para la configuración de culturas laborales inclusivas que respondan a las demandas sociales de equidad y respeto por la diversidad. Justamente, la viabilidad de adoptar estrategias que mitiguen el sesgo algorítmico resulta factible mediante la implementación de metodologías de auditoría algorítmica, el desarrollo de criterios de transparencia y la aplicación de principios de diseño centrados en el ser humano (Raji et al., 2020). A su vez, la creciente disponibilidad de investigaciones empíricas y marcos normativos en desarrollo, como las directrices de la Unión Europea sobre IA confiable, ofrecen un contexto propicio para avanzar en la adopción de prácticas responsables (European Commission, 2021). Por ello, resulta oportuno realizar una revisión exhaustiva de la literatura científica actual que permita identificar, categorizar y analizar críticamente las estrategias orientadas a promover la diversidad y la inclusión en los procesos de reclutamiento asistidos por IA.

El objetivo principal de este estudio es sistematizar el conocimiento disponible sobre las prácticas y enfoques emergentes que buscan equilibrar la eficiencia tecnológica con el compromiso ético de reducir las desigualdades en el acceso al empleo. Al compilar y analizar las evidencias existentes, se pretende ofrecer un panorama comprensivo que facilite el diseño de políticas organizacionales informadas, contribuyendo así a la consolidación de procesos de selección más transparentes, inclusivos y justos en entornos mediados por inteligencia artificial.

2. Materiales y métodos

La presente investigación se desarrolló bajo un enfoque exploratorio de revisión bibliográfica, orientado a identificar, describir y sistematizar las estrategias propuestas y aplicadas para promover la diversidad y la inclusión en los procesos de reclutamiento mediados por sistemas de inteligencia artificial. Este enfoque permitió recopilar y analizar la evidencia científica existente, así como los lineamientos normativos y los informes técnicos publicados por organismos internacionales, con el propósito de conformar una visión integradora del estado actual del conocimiento sobre la materia.

Para la selección de la literatura se definieron criterios de inclusión que contemplaron artículos científicos publicados en revistas indexadas en bases de datos de prestigio, como Scopus y Web of Science, en el periodo comprendido entre 2013 y 2024. Se priorizaron estudios empíricos, revisiones sistemáticas, reportes técnicos y documentos de organismos de regulación tecnológica que abordaran, de manera explícita, las prácticas orientadas a mitigar sesgos algorítmicos, promover la equidad

de oportunidades y garantizar la transparencia de los procesos de selección asistidos por inteligencia artificial. Asimismo, se consideraron contribuciones que examinaran los impactos éticos y organizacionales derivados de la aplicación de dichos sistemas.

La búsqueda bibliográfica se efectuó mediante el uso de palabras clave y operadores booleanos que combinaron términos relacionados con inteligencia artificial, reclutamiento, sesgo, diversidad, inclusión y auditoría algorítmica. Entre los descriptores empleados se incluyeron expresiones como “AI recruitment”, “algorithmic bias”, “inclusive hiring”, “diversity strategies” y “fairness in machine learning”. Estas combinaciones se aplicaron en los motores de búsqueda especializados de cada base de datos, con el fin de maximizar la exhaustividad de los resultados y minimizar la omisión de publicaciones relevantes.

Una vez obtenidos los registros, se procedió a la depuración y análisis preliminar de los títulos y resúmenes, descartando aquellos documentos que no se encontraran directamente relacionados con el objeto de estudio o que carecieran de pertinencia temática. Posteriormente, se efectuó una lectura integral de los textos completos seleccionados, lo que permitió clasificar las evidencias conforme a categorías analíticas predefinidas: estrategias de mitigación del sesgo, prácticas de transparencia y explicabilidad, mecanismos de evaluación y control, y experiencias organizacionales en la adopción de tecnologías inclusivas.

El procedimiento de análisis se desarrolló de manera cualitativa, mediante un proceso de codificación abierta y axial, orientado a identificar patrones recurrentes, convergencias teóricas y vacíos de conocimiento presentes en la literatura revisada. Para garantizar la rigurosidad del proceso, se elaboró una matriz de sistematización de información que permitió organizar los principales hallazgos en relación con los objetivos del estudio. Finalmente, se realizó una síntesis narrativa de los resultados, con el propósito de ofrecer una visión comprensiva y argumentada de las principales estrategias emergentes y de los desafíos asociados a la promoción de la diversidad e inclusión en entornos de reclutamiento asistidos por inteligencia artificial.

3. Resultados

3.1. Mitigación del sesgo algorítmico

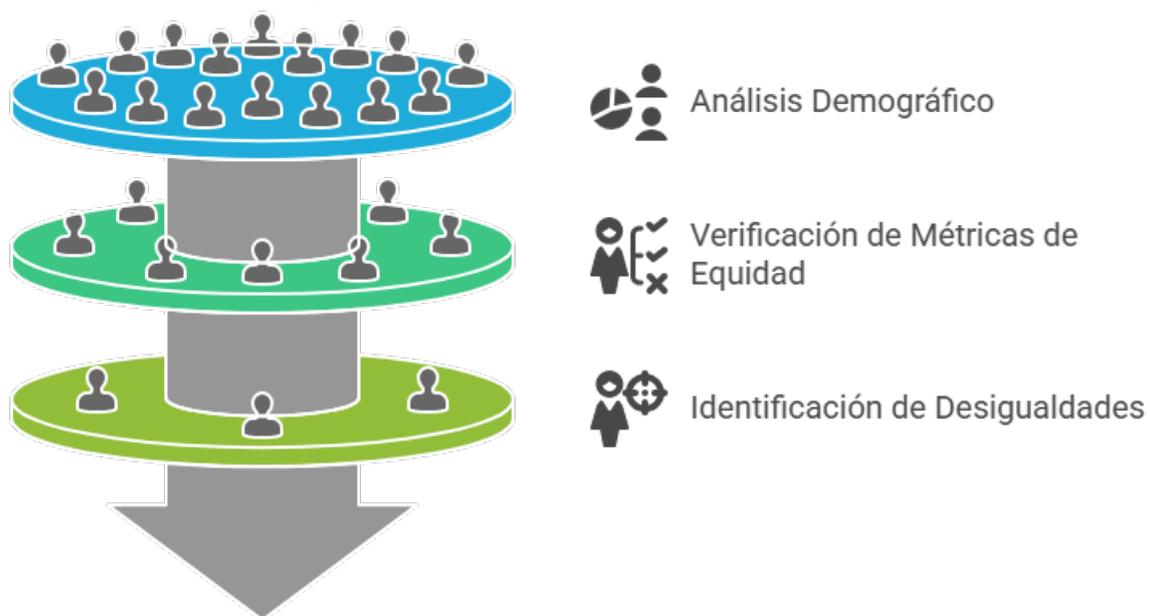
El sesgo algorítmico constituye una de las problemáticas más relevantes en la adopción de sistemas de inteligencia artificial para el reclutamiento, ya que la perpetuación de desigualdades históricas a través de modelos predictivos puede erosionar la confianza pública, afectar la legitimidad de los procesos y desencadenar consecuencias legales y reputacionales adversas. En este sentido, la literatura científica y los marcos de gobernanza han propuesto cuatro estrategias esenciales para reducir estos riesgos: la implementación de auditorías para detectar sesgos, el uso de datos balanceados, la aplicación de técnicas de desbiasado y la conformación de equipos multidisciplinarios.

3.1.1. Auditorías para detectar sesgos

Las auditorías algorítmicas son procesos sistemáticos de evaluación cuyo propósito es identificar y documentar posibles desigualdades en el rendimiento y la toma de decisiones de los modelos de IA. Este procedimiento se basa en el análisis comparativo del comportamiento del sistema en distintos subgrupos demográficos, así como en la verificación de las métricas de equidad definidas previamente (Raji et al., 2020), la figura 1 nos indica que la auditoría algorítmica es un procedimiento fundamental para garantizar que los sistemas de inteligencia artificial empleados en la selección de personal operen de manera justa e inclusiva.

Figura 1

Proceso de Auditoría Algorítmica en Reclutamiento



Nota: La implementación rigurosa de auditorías algorítmicas fortalece la transparencia organizacional y contribuye a mitigar el sesgo discriminatorio en los procesos de contratación automatizados (Autores, 2024).

Herramientas como Aequitas, desarrolladas por investigadores de Data Science for Social Good, proporcionan un marco metodológico para calcular indicadores como la paridad de falsos positivos, la tasa de selección y la equidad predictiva, que permiten evaluar con rigor la distribución de resultados (Saleiro et al., 2018). Adicionalmente, en algunos entornos corporativos se han incorporado auditorías externas independientes con el objetivo de fortalecer la transparencia y la rendición de cuentas ante posibles cuestionamientos sociales (Raji & Buolamwini, 2019).

Por ejemplo, Raji y colaboradores (2020) destacan que una auditoría robusta no solo considera la etapa final de predicción, sino que examina todas las fases del pipeline de datos, incluyendo la recolección, el preprocesamiento, el entrenamiento y la validación del modelo. Esta perspectiva integral resulta fundamental, pues muchos de los sesgos más insidiosos emergen en fases tempranas del ciclo de vida de la inteligencia artificial, donde suelen pasar desapercibidos.

3.1.2. Uso de datos balanceados

Una de las principales causas del sesgo algorítmico radica en la utilización de datos históricos que reflejan desigualdades sistémicas. Por ello, el uso de datasets balanceados es un principio esencial para promover la equidad en los sistemas de reclutamiento automatizado. Buolamwini y Gebru (2018) demostraron que los sistemas comerciales de reconocimiento facial exhibían tasas de error superiores al 30% en mujeres de piel oscura debido a conjuntos de entrenamiento desproporcionadamente dominados por rostros masculinos y de tez clara.

Este hallazgo motivó la adopción de estrategias de muestreo estratificado y enriquecimiento de datos con ejemplos representativos de grupos subrepresentados. En el ámbito del reclutamiento, se recomienda incorporar registros históricos que reflejen una variedad demográfica, profesional y geográfica, así como asegurar la diversidad de variables sociodemográficas relevantes (Ferrara, 2024).

Además, las directrices europeas sobre inteligencia artificial confiable subrayan que la transparencia en la procedencia de los datos y la documentación de los criterios de selección constituyen requisitos indispensables para valorar la legitimidad del proceso (European Commission, 2021). Este enfoque no solo previene la replicación de sesgos históricos, sino que contribuye a construir modelos más generalizables y robustos.

3.1.3. Técnicas de desbiasado

El desbiasado algorítmico comprende un conjunto de metodologías orientadas a reducir la discriminación en los sistemas de IA mediante intervenciones técnicas que pueden aplicarse antes, durante o después del entrenamiento. Según Mehrabi et al. (2021), estas técnicas se clasifican en tres categorías principales:

1. Preprocesamiento, que modifica los datos de entrada mediante reweighting, re-sampling o generación sintética de ejemplos minoritarios.
2. In-training, que introduce restricciones de equidad en la función de pérdida del modelo, de manera que la optimización considera simultáneamente precisión y paridad.
3. Postprocesamiento, que ajusta las predicciones finales aplicando transformaciones para lograr una distribución equitativa.

En particular, los métodos de reweighting consisten en asignar un peso diferencial a las instancias durante el entrenamiento, favoreciendo la contribución de registros menos representados a la optimización del modelo (Kamiran & Calders, 2012). Por su parte, investigaciones recientes exploran técnicas más avanzadas como el affine concept editing, que interviene en las activaciones internas de los modelos de lenguaje grande para suprimir relaciones no deseadas entre atributos demográficos y resultados (Alameda, 2021).

Estas prácticas permiten reducir la brecha de rendimiento entre subgrupos y fortalecer la credibilidad de las decisiones algorítmicas. Sin embargo, su implementación requiere un equilibrio cuidadoso para evitar comprometer la validez predictiva y generar otros tipos de sesgos indirectos.

3.1.4. Equipos multidisciplinarios

La complejidad ética, técnica y normativa que supone la mitigación del sesgo algorítmico hace imprescindible la participación de equipos multidisciplinarios en el diseño y validación de estos sistemas. Kuhlman, Jackson y Chunara (2020) argumentan que la inclusión de perfiles provenientes de ciencias sociales, derecho, psicología organizacional y análisis de datos facilita la identificación de riesgos emergentes y fomenta una comprensión contextualizada de los impactos distributivos de la IA, en la figura 2 indica la composición de los equipos que desarrollan y supervisan sistemas de inteligencia artificial influye directamente en la capacidad de detectar y reducir sesgos discriminatorios.

Figura 2

Diversidad de Equipos y su Impacto en la Mitigación del Sesgo Algorítmico



Nota: Promover equipos multidisciplinarios y diversos mejora sustancialmente la detección de sesgos y fortalece la transparencia en los procesos algorítmicos (Autores, 2024).

En la práctica, esta colaboración se refleja en la creación de comités internos de revisión de equidad algorítmica, en los que convergen ingenieros de machine learning, expertos en diversidad e inclusión y responsables de cumplimiento normativo. El involucramiento de estos actores permite anticipar escenarios problemáticos, definir umbrales de equidad aceptables y establecer políticas de respuesta frente a hallazgos adversos.

La literatura subraya que la composición heterogénea de los equipos de desarrollo no solo incrementa la calidad técnica de las soluciones, sino que también amplía la

legitimidad social del proceso, promoviendo una mayor aceptación entre los potenciales usuarios (Raji et al., 2020).

4. Discusión

La evidencia recopilada en esta revisión bibliográfica permite sostener que las estrategias de mitigación del sesgo algorítmico en los procesos de reclutamiento basados en inteligencia artificial constituyen un campo de estudio en consolidación, cuya relevancia es innegable en el contexto contemporáneo de digitalización acelerada y creciente escrutinio ético sobre las tecnologías emergentes. Diversos autores coinciden en que la aplicación acrítica de modelos predictivos entrenados con datos históricos tiende a reproducir disparidades estructurales que comprometen el principio de igualdad de oportunidades, erosionando con ello la legitimidad y la confiabilidad de las decisiones de contratación (Buolamwini & Gebru, 2018; Raji et al., 2020). Este fenómeno, conocido como sesgo algorítmico, no se circunscribe únicamente al ámbito técnico, sino que conlleva implicaciones sociales, jurídicas y organizacionales que exigen aproximaciones multidimensionales para su abordaje efectivo.

La implementación de auditorías sistemáticas de equidad se erige como uno de los mecanismos más relevantes para identificar, documentar y mitigar las disparidades en el rendimiento de los modelos. Tal como señalan Saleiro et al. (2018), herramientas como Aequitas posibilitan un análisis detallado de métricas de paridad que permiten visibilizar patrones de exclusión invisibilizados en etapas iniciales del desarrollo. No obstante, la eficacia de estas auditorías depende de la voluntad institucional de asumir sus resultados como insumo para la corrección continua, aspecto que en la práctica puede enfrentarse a tensiones derivadas de prioridades comerciales o limitaciones regulatorias (Raji & Buolamwini, 2019).

Por su parte, el uso de datos balanceados ha demostrado ser un componente esencial en la reducción de sesgos, dado que la calidad y representatividad de los conjuntos de entrenamiento condicionan de manera determinante la imparcialidad de los sistemas resultantes (Ferrara, 2024). La experiencia documentada por Buolamwini y Gebru (2018) en el ámbito del reconocimiento facial evidencia que la ausencia de diversidad en los datos puede derivar en tasas de error desproporcionadas para grupos específicos, con consecuencias éticas y legales relevantes. En este sentido, la transparencia en la documentación de las fuentes de datos y la implementación de políticas de gobernanza que garanticen la diversidad demográfica constituyen requisitos sine qua non para la legitimación social de estos sistemas (European Commission, 2021).

Las técnicas de desbiasado se han consolidado como una vía complementaria de intervención que permite mitigar las disparidades residuales mediante ajustes algorítmicos en distintas fases del ciclo de vida del modelo. La literatura coincide en

que metodologías como el reweighting, el re-sampling y las restricciones en la función de pérdida representan alternativas viables para aproximarse a la equidad sin sacrificar de manera significativa el rendimiento predictivo (Kamiran & Calders, 2012; Mehrabi et al., 2021). Sin embargo, estas técnicas no están exentas de controversias, pues algunos estudios advierten que su aplicación puede introducir nuevas formas de discriminación indirecta o generar conflictos con los objetivos de eficiencia y rentabilidad que persiguen las organizaciones (Raji et al., 2020). Este dilema pone en relieve la necesidad de establecer marcos normativos que delimiten con claridad los estándares mínimos de equidad que deben observarse en contextos de alto impacto social (Alameda, 2021).

En relación con la conformación de equipos multidisciplinarios, se observa un consenso creciente sobre su pertinencia como estrategia para prevenir sesgos y anticipar riesgos emergentes. La participación de profesionales provenientes de disciplinas como el derecho, la psicología organizacional y la sociología favorece la incorporación de perspectivas críticas y la identificación de puntos ciegos que suelen pasar inadvertidos en entornos predominantemente técnicos (Kuhlman et al., 2020). Este enfoque inclusivo no solo contribuye a la legitimidad de los procesos, sino que también amplía la capacidad de respuesta de las organizaciones frente a eventuales controversias derivadas del uso de IA en recursos humanos (Raji et al., 2020). No obstante, la evidencia empírica sugiere que el despliegue efectivo de estos equipos requiere una cultura organizacional orientada a la ética y el compromiso sostenido con la equidad, condiciones que no siempre se encuentran garantizadas en todos los contextos (European Commission, 2021).

En suma, los hallazgos de esta revisión ratifican que la mitigación del sesgo algorítmico en los procesos de reclutamiento asistidos por inteligencia artificial demanda la articulación de estrategias técnicas, normativas y organizacionales que trasciendan la mera optimización de métricas de precisión. La convergencia entre auditorías rigurosas, datasets representativos, técnicas de desbiasado y enfoques multidisciplinarios emerge como un enfoque integral con potencial para redefinir los estándares de equidad en la selección de personal. No obstante, persisten retos significativos en materia de transparencia, rendición de cuentas y gobernanza, que constituyen líneas prioritarias de investigación y desarrollo en este campo en evolución.

5. Conclusiones

Las reflexiones derivadas de este estudio permiten reconocer que la adopción de estrategias de diversidad e inclusión en procesos de reclutamiento asistidos por inteligencia artificial no constituye únicamente una tendencia tecnológica, sino una necesidad inaplazable en la construcción de entornos laborales más equitativos y sostenibles. El análisis exhaustivo de la literatura científica evidencia que, si bien la inteligencia artificial ha introducido avances sustanciales en términos de eficiencia y

capacidad predictiva en la selección de personal, su implementación conlleva riesgos latentes de replicar sesgos históricos que afectan de manera desproporcionada a colectivos tradicionalmente subrepresentados. Esta circunstancia obliga a las organizaciones a transitar desde una visión instrumental de la IA hacia una perspectiva crítica que considere las implicaciones éticas, sociales y organizacionales de su uso.

Los hallazgos ponen de manifiesto que ninguna estrategia aislada resulta suficiente para garantizar procesos de reclutamiento verdaderamente justos. Las auditorías periódicas emergen como mecanismos esenciales para identificar disparidades y documentar los impactos diferenciales que se producen en la clasificación de candidatos. Sin embargo, su eficacia depende de que las instituciones asuman un compromiso genuino con la transparencia y la mejora continua. Del mismo modo, la incorporación de datos balanceados en los conjuntos de entrenamiento constituye un requisito indispensable para reducir la incidencia de sesgos estadísticos, aunque esta medida debe complementarse con técnicas de desbiasado que actúen de forma directa sobre los modelos predictivos.

La conformación de equipos multidisciplinarios se ha revelado como un factor decisivo para enriquecer los enfoques técnicos con perspectivas éticas y sociológicas, permitiendo anticipar consecuencias no deseadas y fortalecer la aceptación social de las soluciones automatizadas. Esta integración de saberes contribuye a construir marcos de gobernanza interna que trascienden el cumplimiento meramente formal de las normativas y avanzan hacia una cultura organizacional centrada en la equidad y la rendición de cuentas.

La discusión desarrollada a lo largo del artículo pone de relieve que los desafíos asociados a la mitigación del sesgo algorítmico no pueden resolverse exclusivamente mediante intervenciones técnicas. Si bien las técnicas de reweighting, re-sampling y ajuste de predicciones representan avances importantes, persisten interrogantes sobre sus efectos secundarios y su capacidad de generalizar resultados en contextos laborales diversos. Además, la ausencia de marcos regulatorios específicos en muchas jurisdicciones limita la estandarización de buenas prácticas, generando un panorama de incertidumbre normativa que dificulta la adopción generalizada de estas medidas.

En términos generales, los resultados de esta revisión invitan a repensar el paradigma de eficiencia que durante años ha orientado la implementación de sistemas de IA en la gestión del talento. La búsqueda de precisión predictiva debe equilibrarse con la exigencia de construir procesos inclusivos, transparentes y auditables. Este equilibrio demanda un liderazgo organizacional capaz de priorizar valores éticos sobre lógicas puramente económicas y de asignar los recursos necesarios para la investigación, el monitoreo y la formación de equipos capacitados.

Finalmente, puede afirmarse que el tránsito hacia un reclutamiento basado en inteligencia artificial más justo y diverso depende de la capacidad de las

organizaciones para integrar de manera coherente la innovación tecnológica con principios de equidad sustantiva. Esta integración no solo es deseable, sino imprescindible para responder a las demandas sociales de inclusión y para consolidar la confianza de los candidatos en los procesos de selección. El reto consiste en asumir que la inteligencia artificial no es un ente neutro, sino una construcción sociotécnica cuyas consecuencias dependen en gran medida de las decisiones que adopten quienes diseñan, implementan y supervisan sus sistemas. En esta convergencia de responsabilidades, se delinean las oportunidades más prometedoras para transformar la gestión del talento humano en un ámbito realmente inclusivo y respetuoso de la dignidad de todas las personas.

CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.

Referencias Bibliográficas

- Alameda Castillo, M. T. (2021). *Reclutamiento tecnológico: Sobre algoritmos y acceso al empleo. Temas laborales: Revista andaluza de trabajo y bienestar social*, (159), 11–52. <https://dialnet.unirioja.es/servlet/articulo?codigo=8250088>
- Bravo-Bravo, I. F. (2023). Aplicación de blockchain en la trazabilidad de la cadena de suministro. *Revista Científica Ciencia Y Método*, 1(2), 1-14. <https://doi.org/10.55813/gaea/rcym/v1/n2/11>
- Buolamwini, J., & Gebru, T. (2018). Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification. En *Proceedings of the 1st Conference on Fairness, Accountability and Transparency* (pp. 77–91). *Proceedings of Machine Learning Research*, 81. <https://proceedings.mlr.press/v81/buolamwini18a.html>
- Calvard, T. S., & Jeske, D. (2018). Reporting and recording bias and discrimination in artificial intelligence recruitment. *Employee Relations*, 40(6), 1024–1038.
- Casanova-Villalba, C. I., Herrera-Sánchez, M. J., Lopez-Pincay, P. R., & Rivera-Guerrero, A. L. (2024). Transparencia contable y su relación con la confianza de los inversionistas. *Innova Science Journal*, 2(2), 1-14. <https://doi.org/10.63618/omd/isj/v2/n2/34>
- Casanova-Villalba, C. I., Herrera-Sánchez, M. J., Rivadeneira-Moreira, J. C., Ramos-Secaira, F. M., & Bueno-Moyano, F. R. (2022). *Modelo Kaizen en el sector público*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.2022.8>
- Colina-Vargas, A. M., Espinoza-Mina, M. A., & Silva-Garcés, J. F. (2024). *Dinámicas y tendencias de la ciencia ciudadana en América Latina y el Caribe: Un análisis bibliométrico y temático*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.92>

- Espinosa Vera, A. J., & Mendoza Vargas, E. Y. (2024). *Innovación tecnológica para el desarrollo de los emprendimientos sociales*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.85>
- European Commission. (2021). Proposal for a regulation of the European Parliament and of the Council laying down harmonised rules on artificial intelligence (Artificial Intelligence Act) and amending certain Union legislative acts (COM(2021) 206 final) [Proposal]. EUR-Lex. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52021PC0206>
- Ferrara, E. (2024). Fairness and bias in artificial intelligence: A brief survey of sources, impacts, and mitigation strategies. *Sci*, 6(1), 3. <https://doi.org/10.3390/sci6010003>
- Flores-Murillo, C. R., Hoffmann-Jaramillo, K., Vallejo-López, A. B., & Ana María, S.-R. (2024). *Una ventana abierta hacia la calidad total en un mundo globalizado*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.73>
- Galarza-Sánchez, P. C., Boné-Andrade, M. F., & Pinargote-Bravo, V. J. (2023). Aplicaciones de inteligencia artificial generativa en la transformación digital empresarial. *Revista Científica Ciencia Y Método*, 1(1), 28-41. <https://doi.org/10.55813/gaea/rcym/v1/n1/8>
- Herrera-Sánchez, M. J., Geovely Jaritza, O. J., Quezada Valarezo, Y. D., Rivas Bravo, A. L., Navarrete-Zambrano, C. M., Boné-Andrade, M. F., Parraga-Pether, P. V., Alcívar Vélez, J., Karina Auxiliadora, S. M., Cabrera Aguilar, J. K., Zambrano Flores, P. A., Puyol-Cortez, J. L., Guevara Salcedo, W. A., Urgiles Medina, E. A., Pilatasig Vivanco, M. C., López-Pérez, P. J., Moreira Mendoza, M. B., Vélez Solorzano, B. X., Zambrano Rodríguez, L. A., ... Solórzano Vélez, H. V. (2022). *Análisis Científico de la Ética desde la Perspectiva Multidisciplinaria*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.2022.13>
- Kamiran, F., & Calders, T. (2012). Data preprocessing techniques for classification without discrimination. *Knowledge and Information Systems*, 33(1), 1–33. <https://doi.org/10.1007/s10115-011-0463-8>
- Kim, P. T. (2022). Data-driven discrimination at work. *William & Mary Law Review*, 63(1), 1–64.
- Kuhlman, C., Jackson, L., & Chunara, R. (2020). No computation without representation: Avoiding data and algorithm biases through diversity. *arXiv preprint arXiv:2002.11836*. <https://doi.org/10.48550/arXiv.2002.11836>
- Macias-Loor, J. M., Prado-Chinga, A. E., Alcívar-Soria, E. E., Solano-Gutiérrez, G. A., Quisaguano-Calo, M. F., Cruel-Preciado, M., Endara-Arguello, I. O., Bonilla-Bonilla, M. A., Paredes-Álvarez, P. L., Murillo-Cusme, M. A., Pita-González, G. D., Márquez-Montenegro, K. A., Lirio-Moncayo, V. Y., Riofrio-Casa, D. M., Canchingre-Suárez, K. M., Corozo-Villacis, M. L., Moreira-Mera, J. V., Angulo-Quiñonez, A. D., Vergara-Barragan, J. E., Romero-Pin, M. B., Aviles-Barre, D. A., Quezada-Mazamba, S. N., Rugel-Calderón, F. J., Macías-Alcívar, J. S., Yanchaguano-Loor, A. N., Bone-Quiñonez, E. A., Casanova-Villalba, C. I., Herrera-Sánchez, M. J., & Casanova-Villalba, L. A. (2024). *Gestión Inteligente Sinergias en la Administración*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.106>

- 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), Article 115. <https://doi.org/10.1145/3457607>
- Raghavan, M., Barocas, S., Kleinberg, J., & Levy, K. (2020). Mitigating bias in algorithmic hiring: Evaluating claims and practices. *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency*, 469–481. <https://doi.org/10.1145/3351095.3372828>
- Raji, I. D., & Buolamwini, J. (2019). Actionable auditing: Investigating the impact of publicly naming biased performance results of commercial AI products. *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society*, 429–435. <https://doi.org/10.1145/3306618.3314244>
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Hutchinson, B., Gebru, T., ... & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency (FAT* '20)*, 33–44. <https://doi.org/10.1145/3351095.3372873>
- Rieke, A., & Bogen, M. (2018). Help wanted: An examination of hiring algorithms, equity, and bias. *Upturn*. <https://www.upturn.org/reports/2018/hiring-algorithms/>
- Romero-Reyes, H. D., & Paladines-Torres, L. K. (2024). Análisis Comparativo entre Instrumentos de Evaluación de Clima Laboral y la Evaluación ECLO. *Journal of Economic and Social Science Research*, 4(2), 197–213. <https://doi.org/10.55813/gaeal/jessr/v4/n2/107>
- Saleiro, P., Kuester, B., Hinkson, L., London, J., et al. (2018). Aequitas: A bias and fairness audit toolkit. *arXiv preprint arXiv:1811.05577*. <https://doi.org/10.48550/arXiv.1811.05577>
- Vallejo-Rosero, C. A., Quesada-Paz, M. M., Londoño-Puentes, J. C., & López-Contreras, J. del R. (2024). Factores que afectan el desempeño laboral en el personal de la salud en una IPS de primer nivel en el municipio de Candelaria Valle del Cauca: un análisis para el primer semestre del 2023. *Journal of Economic and Social Science Research*, 4(2), 114–139. <https://doi.org/10.55813/gaeal/jessr/v4/n2/97>
- van Esch, P., Black, J. S., & Ferolie, J. (2019). Marketing AI recruitment: The next phase in job application and selection. *Computers in Human Behavior*, 90, 215–222. <https://doi.org/10.1016/j.chb.2018.09.009>
- Vernaza-Arroyo, G. D., Mina Bone, S. G., Flores Alvarado, E. A., Rueda Orozco, G. J., Zambrano Vélez, D. L., Casanova-Villalba, C. I., Intriago Sánchez, J. E., Molina Valdez, L. A., Moreira Vera, N. C., Proaño-Gonzalez, E. A., Escobar Quiña, J. D., Gómez Pacheco, M. I., Cruz Campos, D. C., Salgado Ortiz, P. J., Avilés Bravo, V. I., Espín Chila, D. M., Fuentes Mora, A. M., Ruiz Zambrano, L. G., Benavidez Mendoza, M. G., Pin Zamora, L. F. (2022). *Resultados Científicos de la Investigación Multidisciplinaria desde la Perspectiva Ética*. Editorial Grupo AEA. <https://doi.org/10.55813/egaea.l.2022.14>