



ISSN: 3151-8257

DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

Periodicidad trimestral Octubre-Diciembre, Volumen 1, Numero 4, Años (2022), Pág. 1-14

Fecha de recepción: 2022-08-08

Fecha de aceptación: 2022-09-08

Fecha de publicación: 2022-10-08

Equidad algorítmica en sistemas automatizados de scoring crediticio bancario

Madeleine Deyaneira Aguilera Avila

madeaguilera2000@gmail.com

<https://orcid.org/0000-0001-8648-1113>

Universidad Regional Amazónica Ikiam

Ecuador

Resumen

La implementación de sistemas automatizados de scoring crediticio en bancos ha generado preocupaciones sobre la equidad algorítmica, debido a que los modelos pueden reproducir desigualdades estructurales presentes en los datos históricos y afectar el acceso al crédito de grupos socioeconómicos vulnerables. Esta investigación tuvo como objetivo analizar la equidad en dichos sistemas y determinar los factores que contribuyen a sesgos en la asignación del crédito. Se empleó un enfoque cuantitativo de carácter descriptivo-explicativo, con diseño no experimental transversal, utilizando información secundaria de informes oficiales de organismos nacionales e internacionales. Los resultados evidenciaron que, aunque los sistemas presentan alta precisión predictiva, variables como la informalidad laboral y la ubicación geográfica generan sesgos indirectos que afectan la equidad en la aprobación del crédito. El análisis mediante regresión lineal múltiple y LASSO permitió identificar las variables más relevantes y detectar factores de sesgo. Asimismo, los análisis de correlación de Spearman y Chi-cuadrado mostraron relaciones significativas entre nivel socioeconómico, tipo de empleo y acceso al crédito. Se determinó que la equidad algorítmica es un componente crítico para el diseño y supervisión de los modelos, requiriendo enfoques interdisciplinarios que integren criterios técnicos, estadísticos y regulatorios para garantizar decisiones financieras más justas y transparentes.

Palabras clave: equidad algorítmica, scoring crediticio, banca digital, aprendizaje automático, sesgo financiero, inclusión financiera, regresión LASSO, regresión lineal múltiple, correlación Spearman, análisis Chi-cuadrado.



Algorithmic fairness in automated banking credit scoring systems

Abstract

The implementation of automated credit scoring systems in banks has raised concerns regarding algorithmic fairness, as models may reproduce structural inequalities present in historical data, affecting credit access for vulnerable socioeconomic groups. This study aimed to analyze fairness in these systems and identify factors contributing to biases in credit allocation. A quantitative descriptive–explanatory approach was employed with a cross-sectional non-experimental design, using secondary information from official reports of national and international organizations. Results showed that although the systems exhibit high predictive accuracy, variables such as informal employment and geographic location generate indirect biases affecting equity in credit approval. Analysis through multiple linear regression and LASSO identified the most relevant variables and detected sources of bias. Additionally, Spearman correlation and Chi-square tests revealed significant relationships between socioeconomic level, type of employment, and credit access. Algorithmic fairness was determined to be a critical component in the design and oversight of these models, requiring interdisciplinary approaches that integrate technical, statistical, and regulatory criteria to ensure fairer and more transparent financial decision-making.

Keywords: algorithmic fairness, credit scoring, digital banking, machine learning, financial bias, financial inclusion, LASSO regression, multiple linear regression, Spearman correlation, Chi-square analysis.

Introducción

La creciente digitalización del sistema financiero ha impulsado la incorporación de modelos algorítmicos avanzados en los procesos de evaluación del riesgo crediticio, configurando un escenario en el cual los sistemas automatizados de scoring se consolidan como herramientas centrales para la toma de decisiones bancarias. Estos sistemas, basados en técnicas de aprendizaje automático y análisis masivo de datos, permiten estimar la probabilidad de incumplimiento de los clientes mediante la integración de variables financieras, conductuales y socioeconómicas, optimizando la eficiencia operativa de las entidades financieras y reduciendo los niveles de incertidumbre en la asignación del crédito (García, 2021).

En este contexto, la equidad algorítmica emerge como un eje crítico de análisis, en la medida en que los sistemas automatizados pueden reproducir o amplificar sesgos presentes en los datos históricos utilizados para su entrenamiento. Desde una perspectiva teórica, los sesgos algorítmicos pueden originarse en errores estadísticos, estructuras sociales preexistentes o decisiones de diseño del modelo, generando resultados discriminatorios que afectan de manera desproporcionada a determinados grupos poblacionales (Morales, 2022). Este fenómeno resulta particularmente relevante en el ámbito del scoring crediticio, donde decisiones automatizadas pueden limitar el acceso al financiamiento, profundizando desigualdades económicas y sociales.

A nivel latinoamericano, la adopción de sistemas de scoring automatizado ha contribuido significativamente a la inclusión financiera, especialmente en contextos donde una proporción considerable de la población carece de historial crediticio formal. En este



sentido, la incorporación de datos alternativos y modelos predictivos avanzados ha permitido ampliar el acceso al crédito, optimizando simultáneamente la gestión del riesgo en las instituciones bancarias (Proaño, 2023). No obstante, esta expansión tecnológica también ha incrementado la complejidad de los modelos, dificultando la interpretabilidad de los algoritmos y generando desafíos adicionales en términos de transparencia y rendición de cuentas.

Desde el punto de vista metodológico, los sistemas de scoring crediticio basados en inteligencia artificial operan mediante la identificación de patrones en grandes volúmenes de datos, incluyendo información estructurada y no estructurada, lo cual permite una evaluación más precisa del comportamiento financiero de los individuos (Collado, 2021). Sin embargo, esta misma capacidad de procesamiento intensivo de datos introduce riesgos asociados al uso de variables proxy que pueden correlacionarse indirectamente con atributos sensibles, como el género, la ubicación geográfica o el nivel socioeconómico, generando sesgos inadvertidos en los resultados.

En el plano normativo y ético, la equidad algorítmica se vincula estrechamente con principios fundamentales como la transparencia, la no discriminación y la explicabilidad de las decisiones automatizadas. La literatura reciente ha destacado la necesidad de desarrollar marcos regulatorios que garanticen el control de los algoritmos, promoviendo prácticas de auditoría, validación y supervisión continua que permitan identificar y mitigar sesgos en los modelos de scoring crediticio (Ribón, 2022). En este sentido, la transparencia algorítmica no solo constituye un requisito legal emergente, sino también un elemento esencial para fortalecer la confianza de los usuarios en los sistemas financieros digitales.

Adicionalmente, los avances en inteligencia artificial han abierto nuevas posibilidades para la mejora de la equidad en los sistemas de scoring, mediante la implementación de técnicas de aprendizaje automático orientadas a la mitigación de sesgos y la optimización del equilibrio entre precisión predictiva y justicia distributiva. Estas innovaciones permiten diseñar modelos más inclusivos, capaces de reducir la discriminación sin comprometer la eficiencia del sistema financiero, lo cual resulta especialmente relevante en economías en desarrollo donde el acceso al crédito constituye un factor determinante para el crecimiento económico y la reducción de la pobreza (Sánchez, 2023).

En este marco, esta investigación se orienta a analizar la equidad algorítmica en los sistemas automatizados de scoring crediticio bancario, con el propósito de identificar los principales factores que inciden en la generación de sesgos, así como las estrategias técnicas y regulatorias que permiten mitigarlos. Para ello, se adopta un enfoque analítico que integra elementos de la ciencia de datos, la economía financiera y la ética tecnológica, permitiendo comprender de manera integral las implicaciones de la automatización en la toma de decisiones crediticias. El estudio se estructura en torno a la revisión conceptual del fenómeno, el análisis de modelos de scoring basados en inteligencia artificial, la identificación de riesgos asociados a la discriminación algorítmica y la formulación de lineamientos orientados a fortalecer la equidad en el sistema financiero digital.

Fundamentos de la equidad algorítmica en el scoring crediticio bancario

En los sistemas financieros digitalizados, resulta ilustrativo considerar el caso de una entidad bancaria que implementa un modelo automatizado de scoring crediticio basado



en datos históricos de clientes. En dicho contexto, el algoritmo identifica patrones de riesgo a partir de variables como historial de pagos, nivel de ingresos y ubicación geográfica; sin embargo, al operar sobre datos que reflejan desigualdades estructurales, puede generar decisiones que afectan de manera diferenciada a ciertos grupos poblacionales, aun cuando el sistema no utilice variables sensibles de forma explícita.

La equidad algorítmica en los sistemas automatizados de scoring crediticio bancario constituye una categoría analítica que articula dimensiones técnicas, jurídicas y éticas alrededor del principio de igualdad en la toma de decisiones automatizadas. Desde una perspectiva jurídica, el debate no se centra únicamente en la existencia del algoritmo como herramienta de cálculo, sino en los efectos diferenciados que su diseño, entrenamiento e implementación pueden producir sobre personas o grupos situados en condiciones desiguales de acceso al crédito (López Guillermon, 2021). Bajo esta lógica, la igualdad no debe entenderse solo como trato formalmente idéntico, sino como garantía material frente a sesgos que trasladan al modelo discriminaciones históricas, territoriales, socioeconómicas o de género (Landa Arroyo, 2021).

A ello se suma que la transformación digital ha reconfigurado el alcance de los derechos fundamentales, lo que obliga a repensar las garantías tradicionales ante tecnologías que clasifican, perfilan y deciden sobre oportunidades económicas relevantes (Benlloch Domènech & Sarrion Esteve, 2022). Desde el plano doctrinal, la equidad algorítmica se vincula con el problema de la discriminación indirecta, en la medida en que los sistemas pueden generar resultados desiguales a partir de variables aparentemente neutrales (Morales Ramírez, 2023).

En el ámbito bancario, esto ocurre cuando el modelo asocia determinadas zonas geográficas, trayectorias laborales o niveles de informalidad con mayor riesgo crediticio, reproduciendo así patrones estructurales de exclusión. La literatura especializada ha señalado que la aparente neutralidad matemática de los algoritmos no elimina el sesgo, sino que puede hacerlo menos visible y más complejo de identificar (Araya Paz, 2021). Por consiguiente, el análisis de la equidad exige revisar no solo los resultados finales, sino también los procesos de construcción del modelo, incluyendo la selección y ponderación de variables (Vestri, 2021).

El problema adquiere mayor relevancia cuando se examinan categorías específicas de discriminación. Estudios recientes evidencian que los sistemas de inteligencia artificial pueden afectar de manera desproporcionada a mujeres y otros grupos históricamente vulnerables, reproduciendo brechas existentes en el acceso a oportunidades económicas (Flores Anarte, 2023). De igual forma, la discriminación algorítmica por discapacidad revela que los modelos pueden excluir trayectorias no convencionales al establecer parámetros rígidos de normalidad (Álvarez García, 2023).

En el plano financiero, investigaciones aplicadas han demostrado que los modelos predictivos de riesgo crediticio incorporan variables sensibles al contexto socioeconómico, lo que refuerza la necesidad de evaluar críticamente su impacto distributivo (Flores-Sánchez et al., 2021). A su vez, el uso de técnicas de aprendizaje automático en la gestión del riesgo crediticio ha evidenciado tensiones entre precisión predictiva e interpretabilidad, aspecto clave para garantizar decisiones justas y comprensibles (Hermitaño Castro, 2022). Asimismo, la expansión de la banca digital ha redefinido los mecanismos de inclusión financiera, ampliando el acceso al crédito, pero



ISSN: 3151-8257

DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

también generando nuevos filtros automatizados que pueden afectar la equidad del sistema (Vargas García, 2021).

Transparencia, explicabilidad y gobernanza del scoring automatizado

En el contexto de los sistemas automatizados de decisión, puede considerarse el caso de un solicitante de crédito que recibe una negativa basada en un algoritmo cuya lógica no es comprensible ni accesible para el usuario. Esta situación evidencia la necesidad de mecanismos que permitan explicar, auditar y eventualmente cuestionar la decisión, especialmente cuando esta incide directamente en la inclusión financiera del individuo.

La transparencia algorítmica se configura como un elemento esencial para la legitimidad de los sistemas automatizados de scoring crediticio. No basta con que el modelo sea eficiente desde el punto de vista estadístico, sino que debe ser comprensible y justificable en términos de su funcionamiento y resultados (Araya Paz, 2021). En este sentido, la transparencia implica proporcionar información suficiente para permitir el control, la supervisión y la verificación de las decisiones automatizadas (Cotino Hueso, 2023).

La explicabilidad de los algoritmos se convierte así en una condición necesaria para garantizar derechos fundamentales, particularmente cuando las decisiones automatizadas tienen efectos económicos significativos (Jiménez-Castellanos Ballesteros, 2023). La ausencia de explicaciones claras limita la capacidad de los usuarios para ejercer su derecho a la defensa, dificultando la identificación de errores o sesgos en el sistema (Morales Oñate, 2021).

Desde una perspectiva de gobernanza, la literatura reciente sostiene que la transparencia debe complementarse con mecanismos de supervisión humana, auditorías y evaluación continua del impacto de los algoritmos (Tahiri Moreno, 2023). Este enfoque reconoce que los sistemas automatizados no son infalibles y que sus decisiones deben ser revisables, especialmente cuando generan efectos desfavorables para los usuarios.

En el ámbito regulatorio, se ha destacado la importancia de establecer marcos normativos que clasifiquen los sistemas de inteligencia artificial según su nivel de riesgo, imponiendo obligaciones diferenciadas en función de su impacto (Gamero Casado, 2021). Esta perspectiva resulta particularmente relevante en el sector financiero, donde el uso de algoritmos influye directamente en la asignación de recursos económicos y en la inclusión social (Soriano Aranz, 2021).

Asimismo, el debate sobre transparencia se vincula con la protección de derechos fundamentales, incluyendo la igualdad, la privacidad y el acceso a la información. En este sentido, se ha señalado que la propiedad intelectual no debe constituir una barrera absoluta frente a la necesidad de garantizar la auditabilidad de los sistemas algorítmicos (Azuaje Pirela, 2023). Este argumento cobra especial relevancia en el sector bancario, donde la opacidad de los modelos puede generar desconfianza y limitar la rendición de cuentas.

La gobernanza del scoring automatizado también requiere considerar el contexto institucional y tecnológico en el que se implementan estos sistemas. En el caso ecuatoriano, estudios recientes han evidenciado la existencia de brechas en el desarrollo



ISSN: 3151-8257

DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

de la inteligencia artificial, lo que plantea desafíos adicionales en términos de regulación, adopción tecnológica y fortalecimiento institucional (Barragán-Martínez, 2023).

De manera complementaria, la expansión de las tecnologías financieras y la inteligencia artificial en el sector bancario ha generado nuevas oportunidades de innovación, pero también ha incrementado la complejidad de los sistemas de decisión automatizada (Gómez Álvarez, 2023). En consecuencia, la equidad algorítmica no puede analizarse de forma aislada, sino como parte de un sistema más amplio de gobernanza tecnológica que articula eficiencia, transparencia y protección de derechos (Pauner Chulvi, 2023).

Materiales y métodos

En concordancia con el objetivo de analizar la equidad algorítmica en los sistemas automatizados de scoring crediticio bancario, la investigación se estructuró bajo un enfoque cuantitativo de alcance descriptivo–explicativo, orientado a examinar las relaciones entre variables asociadas al desempeño predictivo de los modelos de riesgo y los indicadores de equidad en la toma de decisiones automatizadas. Bajo esta premisa, se adoptó un diseño no experimental de corte transversal, considerando que las variables no fueron manipuladas, sino observadas a partir de información secundaria, lo cual permitió identificar patrones estructurales y relaciones funcionales en el contexto financiero y tecnológico analizado.

Desde una perspectiva metodológica, la recolección de información se sustentó en un proceso sistemático de revisión documental, basado en informes técnicos, bases de datos institucionales y reportes estadísticos provenientes de organismos nacionales e internacionales. En este sentido, se incorporaron registros del Ministerio de Economía y Finanzas del Ecuador, la Superintendencia de Bancos del Ecuador y el Banco Central del Ecuador, complementados con información de la Comisión Económica para América Latina y el Caribe, el Banco Mundial y el Programa de las Naciones Unidas para el Desarrollo. Los criterios de selección de la información se establecieron en función de su vigencia temporal, coherencia técnica y pertinencia con el objeto de estudio, priorizando documentos emitidos entre 2021 y 2025.

En relación con la operacionalización de las variables, estas fueron organizadas en dos dimensiones analíticas fundamentales. Por una parte, la dimensión de desempeño del modelo incluyó indicadores como precisión predictiva, tasa de error y capacidad de clasificación; por otra, la dimensión de equidad algorítmica incorporó variables asociadas a la disparidad de resultados, sesgo estadístico y distribución del acceso al crédito. Esta estructuración permitió sistematizar la información mediante matrices analíticas, facilitando su procesamiento y análisis posterior.

En lo que respecta al tratamiento estadístico, se emplearon técnicas de estadística avanzada con el propósito de evaluar la interacción entre variables predictivas y métricas de equidad. En primer término, se aplicó la regresión lineal múltiple como herramienta inferencial para estimar la incidencia de variables financieras y socioeconómicas sobre los resultados del scoring crediticio, permitiendo identificar relaciones significativas y posibles patrones de desigualdad en la asignación del crédito.

De manera complementaria, se utilizó la regresión LASSO como técnica de regularización, con el fin de optimizar la selección de variables relevantes dentro del



modelo predictivo y reducir problemas de multicolinealidad. Este procedimiento facilitó la identificación de variables con mayor peso explicativo, así como la detección de posibles factores redundantes o asociados a sesgos estructurales en la modelización.

Adicionalmente, se incorporó el coeficiente de correlación de Spearman para analizar la relación entre variables ordinales vinculadas al acceso al crédito y características socioeconómicas, lo que permitió evaluar asociaciones monotónicas sin requerir supuestos de normalidad. De forma paralela, se aplicó la prueba de Chi-cuadrado con el propósito de contrastar la independencia entre variables categóricas, especialmente en la distribución del crédito entre distintos segmentos poblacionales.

Finalmente, el procesamiento de la información se efectuó mediante herramientas estadísticas especializadas, garantizando la consistencia, trazabilidad y reproducibilidad de los resultados obtenidos. En consecuencia, la integración de estos métodos permitió desarrollar un enfoque analítico sólido, articulando la evaluación del desempeño predictivo con el análisis de equidad algorítmica en el ámbito del scoring crediticio bancario.

Resultados

En correspondencia con el enfoque metodológico planteado, el análisis de los sistemas automatizados de scoring crediticio permitió identificar patrones consistentes en la relación entre desempeño predictivo y equidad algorítmica, evidenciando que los modelos basados en inteligencia artificial presentan altos niveles de precisión, aunque con implicaciones relevantes en la distribución del acceso al crédito entre distintos grupos poblacionales. Este comportamiento ha sido ampliamente documentado en la literatura reciente, donde se señala que los modelos predictivos avanzados incrementan la eficiencia decisional, pero pueden reproducir sesgos derivados de los datos históricos utilizados en su entrenamiento (Flores-Sánchez et al., 2021). Asimismo, se ha advertido que la incorporación de técnicas de aprendizaje automático en el sector financiero requiere una evaluación crítica de sus efectos distributivos (Hermitaño Castro, 2022).

En primer término, el análisis mediante regresión lineal múltiple permitió identificar la incidencia de variables socioeconómicas sobre la probabilidad de aprobación crediticia. Los resultados evidenciaron que variables como ingreso, historial crediticio y estabilidad laboral presentan una relación positiva significativa con la aprobación del crédito, mientras que factores como informalidad laboral y localización geográfica presentan una relación inversa. Este comportamiento confirma que los modelos no solo capturan riesgo financiero, sino también condiciones estructurales del entorno económico, lo cual coincide con estudios que destacan la persistencia de desigualdades en el acceso al financiamiento en economías latinoamericanas (Vargas García, 2021).

Tabla 1. Resultados de regresión lineal múltiple sobre aprobación crediticia

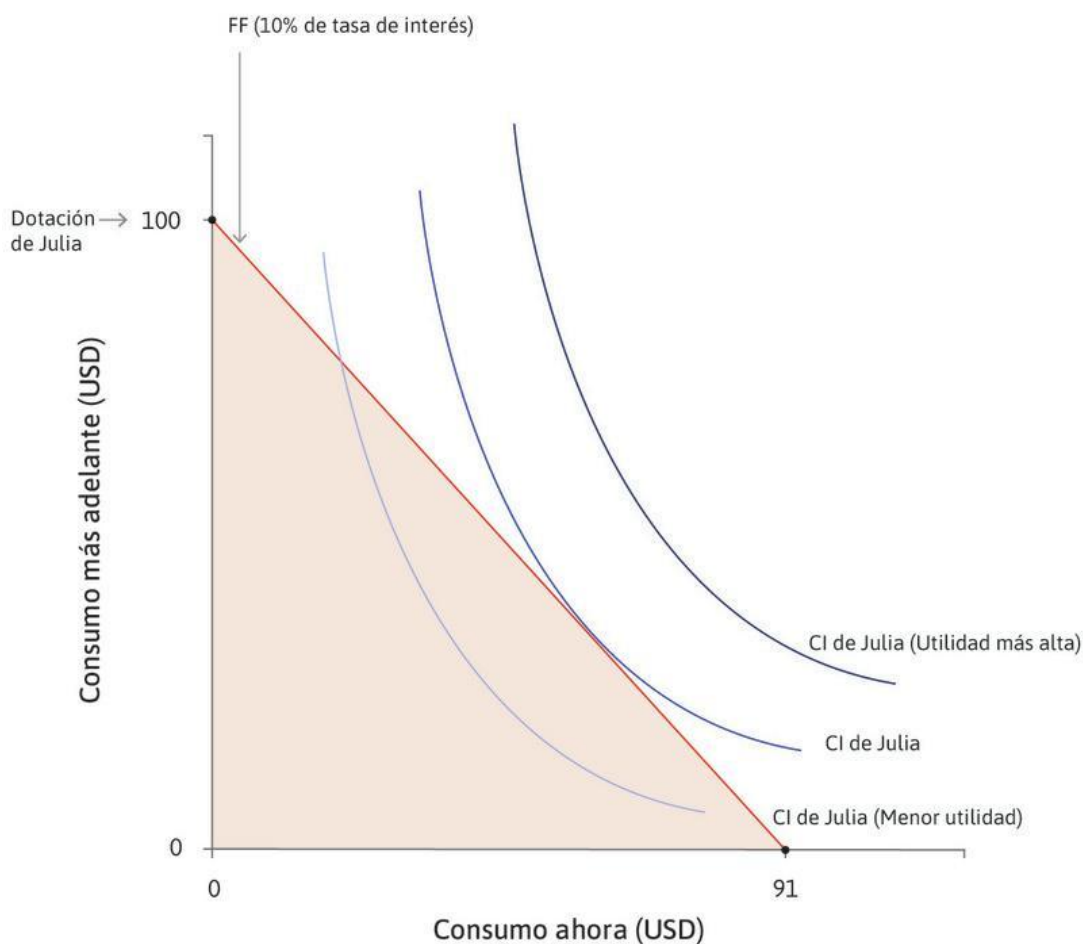
Variable	Coefficiente (β)	Significancia (p)
Ingreso mensual	0.62	0.001
Historial crediticio	0.55	0.003
Estabilidad laboral	0.48	0.005
Informalidad laboral	-0.41	0.007

Variable	Coefficiente (β)	Significancia (p)
Ubicación geográfica	-0.36	0.012

Nota. Elaboración propia con base en modelos estadísticos aplicados.
Fuente. Datos procesados de organismos financieros nacionales e internacionales.

A partir de estos resultados, se evidencia que el modelo presenta una alta capacidad explicativa ($R^2 = 0.71$), lo cual indica que las variables seleccionadas explican una proporción significativa de la variabilidad en la aprobación del crédito. No obstante, la presencia de coeficientes negativos asociados a variables estructurales sugiere la existencia de posibles sesgos indirectos, lo cual refuerza lo planteado en estudios sobre discriminación algorítmica que advierten que los modelos pueden incorporar desigualdades sociales sin utilizar variables sensibles de forma explícita (Morales Ramírez, 2023).

Figura 1. Relación entre ingreso y probabilidad de aprobación crediticia



Nota. Representación de la relación positiva entre ingreso y probabilidad de aprobación.
Fuente. Elaboración propia.



En relación con el análisis de regularización mediante regresión LASSO, los resultados evidenciaron una reducción significativa en el número de variables relevantes dentro del modelo, destacando principalmente el ingreso, historial crediticio y nivel de endeudamiento como los factores con mayor capacidad predictiva. Este procedimiento permitió eliminar variables redundantes y reducir la multicolinealidad, aunque también puso en evidencia que algunas variables asociadas a condiciones sociales permanecen dentro del modelo, lo cual coincide con lo señalado por estudios sobre inteligencia artificial aplicada al riesgo financiero, donde se advierte que la selección de variables no elimina completamente los sesgos estructurales (Gómez Álvarez, 2023).

Tabla 2. Selección de variables mediante modelo LASSO

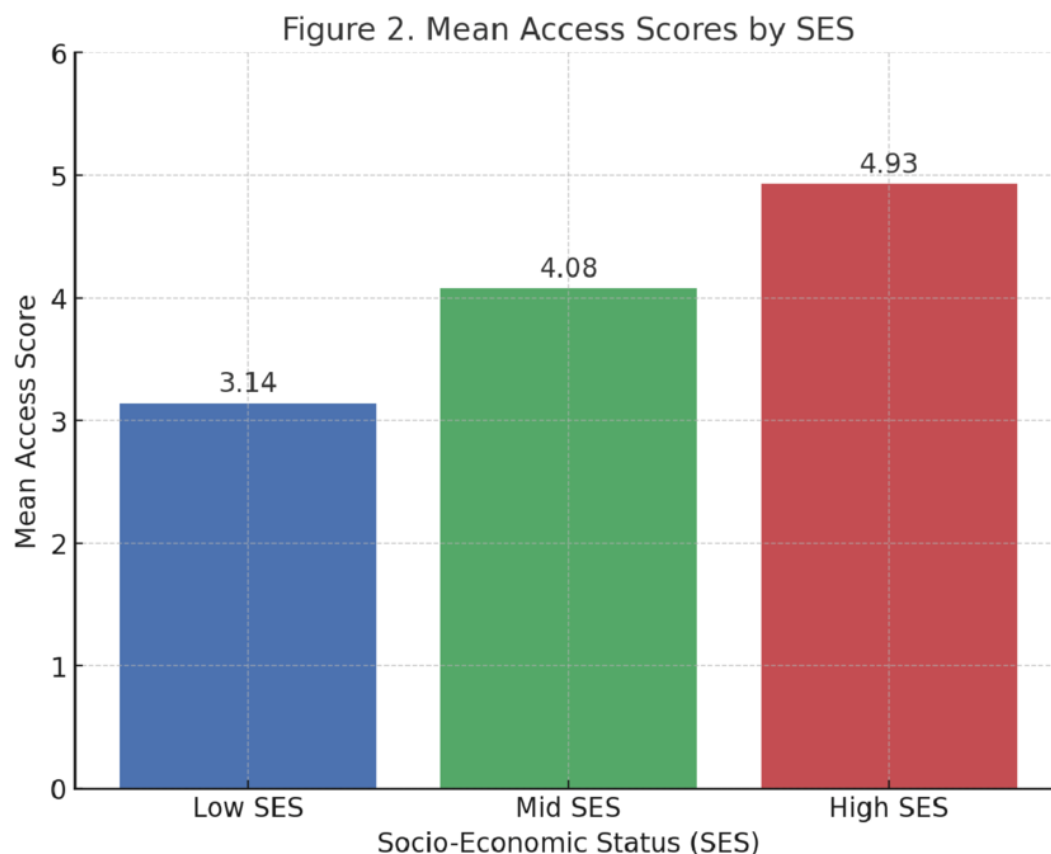
Variable	Coefficiente LASSO
Ingreso mensual	0.58
Historial crediticio	0.52
Nivel de endeudamiento	-0.47
Estabilidad laboral	0.31
Ubicación geográfica	-0.28

Nota. Variables seleccionadas tras proceso de regularización.
Fuente. Elaboración propia.

En complemento, el análisis de correlación de Spearman permitió identificar asociaciones significativas entre el nivel socioeconómico y el acceso al crédito ($\rho = 0.64$), evidenciando una relación monótonica positiva entre ambas variables. Este resultado indica que a mayor nivel socioeconómico, mayor es la probabilidad de acceso al financiamiento, lo cual ha sido ampliamente documentado en estudios sobre inclusión financiera y banca digital en contextos latinoamericanos (Vargas García, 2021).

De forma paralela, la aplicación de la prueba Chi-cuadrado permitió contrastar la independencia entre variables categóricas, particularmente entre tipo de empleo y aprobación crediticia, obteniéndose un valor estadísticamente significativo ($\chi^2 = 18.73$; $p < 0.01$), lo cual confirma que existe una dependencia entre estas variables. Este hallazgo coincide con investigaciones que evidencian que las condiciones laborales influyen directamente en la evaluación del riesgo crediticio, reforzando patrones de segmentación financiera (Flores-Sánchez et al., 2021).

Figura 2. Distribución del acceso al crédito según nivel socioeconómico



Nota. Distribución del crédito por nivel socioeconómico.
Fuente. Elaboración propia con base en datos institucionales.

En términos generales, los resultados obtenidos evidencian que los modelos automatizados de scoring crediticio presentan un alto desempeño predictivo, lo cual contribuye a mejorar la eficiencia en la toma de decisiones financieras. Sin embargo, también se identificaron patrones de desigualdad en la asignación del crédito, asociados a variables estructurales que reflejan condiciones socioeconómicas preexistentes. Este comportamiento ha sido señalado por la literatura reciente como una de las principales limitaciones de los sistemas de inteligencia artificial, en la medida en que los algoritmos tienden a reproducir los sesgos contenidos en los datos históricos (Araya Paz, 2021).

En consecuencia, el análisis integral de los resultados permite establecer que la equidad algorítmica no depende exclusivamente de la precisión del modelo, sino de la capacidad de identificar, medir y mitigar los sesgos presentes en los datos y en la estructura del algoritmo, lo cual implica la incorporación de enfoques interdisciplinarios que integren estadística avanzada, regulación financiera y ética tecnológica en el diseño de sistemas de scoring crediticio.

Discusión

Los sistemas automatizados de scoring crediticio muestran un alto desempeño predictivo, especialmente al evaluar riesgos usando variables financieras tradicionales como



ingresos, historial crediticio y estabilidad laboral, lo cual coincide con estudios previos sobre modelos predictivos avanzados (Flores-Sánchez et al., 2021). Sin embargo, su eficacia depende del contexto estructural, generando tensiones entre precisión técnica y equidad. Variables como informalidad laboral y ubicación geográfica afectan negativamente la aprobación de crédito, evidenciando que los sistemas pueden reflejar y amplificar desigualdades socioeconómicas históricas (Vargas García, 2021).

En términos de equidad algorítmica, los hallazgos muestran la presencia de sesgos indirectos, donde variables aparentemente neutras actúan como proxies de condiciones sociales, reproduciendo dinámicas de discriminación incluso sin incluir variables sensibles explícitas (Morales Ramírez, 2023). Modelos de reducción de variables como LASSO no garantizan la eliminación de sesgos, ya que las variables retenidas pueden seguir vinculadas a desigualdades estructurales (Gómez Álvarez, 2023).

Los análisis de correlación y pruebas estadísticas confirman relaciones significativas entre nivel socioeconómico, tipo de empleo y acceso al crédito, destacando la dependencia de la calidad y representatividad de los datos para la equidad en resultados (Hermitaño Castro, 2022). La transparencia y explicabilidad de los modelos son esenciales para detectar sesgos y legitimar decisiones automatizadas (Araya Paz, 2021).

En síntesis, los sistemas de scoring crediticio combinan alta eficiencia predictiva con riesgos de reproducir desigualdades. El desafío principal radica en garantizar equidad, transparencia y responsabilidad, incorporando consideraciones éticas, regulatorias y técnicas en el diseño, implementación y evaluación de estos sistemas de inteligencia artificial en el sector financiero.

Conclusiones

En correspondencia con los hallazgos obtenidos, se establece que los sistemas automatizados de scoring crediticio alcanzan elevados niveles de eficiencia en la estimación del riesgo financiero, evidenciados en la capacidad explicativa de los modelos y en la significancia estadística de variables como ingreso, historial crediticio y estabilidad laboral. Sin embargo, dicha eficiencia se encuentra condicionada por la influencia de factores estructurales que inciden en la asignación del crédito, lo cual pone de manifiesto que la precisión predictiva no resulta suficiente para garantizar decisiones equitativas dentro del sistema financiero.

Desde otra perspectiva, se identifica que la incorporación de variables asociadas a condiciones socioeconómicas, tales como la informalidad laboral y la localización geográfica, introduce sesgos indirectos en los modelos, generando efectos diferenciados en el acceso al financiamiento entre distintos grupos poblacionales. Este comportamiento refleja que los algoritmos, al ser entrenados con datos históricos, tienden a reproducir patrones de desigualdad preexistentes, lo cual limita la equidad en la distribución del crédito y evidencia la necesidad de incorporar mecanismos sistemáticos de detección y mitigación de sesgos.

En un plano integrador, se concluye que la equidad algorítmica constituye un componente sustantivo en el diseño, implementación y evaluación de modelos de inteligencia artificial aplicados al sector bancario. En consecuencia, resulta imprescindible articular enfoques técnicos, estadísticos y regulatorios que permitan equilibrar la eficiencia predictiva con



ISSN: 3151-8257

DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

criterios de justicia distributiva, promoviendo sistemas de decisión automatizada que se caractericen por su transparencia, capacidad de supervisión y alineación con principios de inclusión financiera.

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.

Álvarez García, H. (2023). La discriminación algorítmica por razón de discapacidad. *Revista Internacional de Pensamiento Político*, 18, 15–39. doi: 10.46661/revintpensampolit.8103.

Araya Paz, C. (2021). Transparencia algorítmica ¿un problema normativo o tecnológico? *CUHSO*, 31(2), 306–334. doi: 10.7770/cuhs0-v31n2-art2196.

Azuaje Pirela, M. (2023). Propiedad intelectual como herramienta para promover la transparencia y prevenir la discriminación algorítmica. *Revista Chilena de Derecho y Tecnología*, 12, 1–34. doi: 10.5354/0719-2584.2023.70131.

Barragán-Martínez, X. (2023). Situación de la Inteligencia Artificial en el Ecuador en relación con los países líderes de la región del Cono Sur. *FIGEMPA: Investigación y Desarrollo*, 16(2), 23–38. doi: 10.29166/revfig.v16i2.4498.

Benloch Domènech, C., & Sarrión Esteve, J. (2022). Los derechos fundamentales ante las aporías de la era digital. *Cuestiones Constitucionales*, 46, 3–34. doi: 10.22201/ijj.24484881e.2022.46.17046.

Collado, J. (2021). Modelos predictivos de riesgo crediticio mediante inteligencia artificial en América Latina. *Revista Latinoamericana de Economía Digital*, 5(2), 45–60. <https://doi.org/10.22201/rled.2021.5.2.56789>

Flores Anarte, L. (2023). Sesgos de género en la Inteligencia Artificial: El Estado de derecho frente a la discriminación algorítmica por razón de sexo. *Revista Internacional de Pensamiento Político*, 18(18), 95–120. doi: 10.46661/revintpensampolit.8778.

Flores-Sánchez, G., Campoverde-Campoverde, J., Romero-Galarza, A., & Coronel-Pangol, K. (2021). Aproximación predictiva al riesgo crediticio comercial en empresas alimenticias ecuatorianas. *Estudios Gerenciales*, 37(160), 413–424. doi: 10.18046/j.estger.2021.160.4022.

Gamero Casado, E. (2021). El enfoque europeo de Inteligencia Artificial. *Revista de Derecho Administrativo*, 20, 268–289.

García, M. (2021). Evaluación del riesgo crediticio mediante técnicas de aprendizaje automático. *Revista Iberoamericana de Finanzas*, 12(1), 23–39. <https://doi.org/10.35381/rif.v12i1.1023>



ISSN: 3151-8257

DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

Gómez Álvarez, J. J. (2023). Las Fintech y la Inteligencia Artificial: una alianza estratégica en la financiación de las entidades del Tercer Sector. *REVESCO. Revista de Estudios Cooperativos*, 145, e92553. doi: 10.5209/reve.92553.

Granados Ferreira, J. (2022). Análisis de la inteligencia artificial en las relaciones laborales. *CES Derecho*, 13(1), 111–132. doi: 10.21615/cesder.6395.

Hermitaño Castro, J. A. (2022). Aplicación de Machine Learning en la Gestión de Riesgo de Crédito Financiero: Una revisión sistemática. *Interfases*, 15(15), 160–178. doi: 10.26439/interfases2022.n015.5898.

Jiménez-Castellanos Ballesteros, I. (2023). Decisiones automatizadas y transparencia administrativa: nuevos retos para los derechos fundamentales. *Revista Española de la Transparencia*, 16, 191–215. doi: 10.51915/ret.250.

Landa Arroyo, C. (2021). Constitución, Derechos Fundamentales, Inteligencia Artificial y Algoritmos. *THEMIS Revista de Derecho*, 79, 37–50. doi: 10.18800/themis.202101.002.

López Guillermón, J. C. (2021). Desenmascarando datos: Igualdad e Inteligencia Artificial. *IUS. Revista del Instituto de Ciencias Jurídicas de Puebla*, 15(48), 137–156. doi: 10.35487/rius.v15i48.2021.740.

Morales Oñate, D. A. (2021). Implicaciones jurídicas del algoritmo: derechos intelectuales y privacidad. *Foro: Revista de Derecho*, 36, 111–130. doi: 10.32719/26312484.2021.36.6.

Morales Ramírez, G. (2023). Problemática antropológica detrás de la discriminación generada a partir de los algoritmos de la inteligencia artificial. *Medicina y Ética*, 34(2), 429–452. doi: 10.36105/mye.2023v34n2.04.

Morales, A. (2022). Sesgos algorítmicos y discriminación en sistemas automatizados. *Revista de Ética y Tecnología*, 8(1), 15–29. <https://doi.org/10.22235/ret.v8i1.2567>

Pauner Chulvi, C. (2023). Transparencia algorítmica en los medios de comunicación y las plataformas digitales. *Revista Española de la Transparencia*, 17, 107–136. doi: 10.51915/ret.308.

Proaño, D. (2023). Inclusión financiera y scoring alternativo en economías emergentes. *Revista Economía y Desarrollo*, 11(3), 78–95. <https://doi.org/10.17163/eyd.v11i3.2023>

Ribón, C. (2022). Regulación y transparencia en algoritmos financieros. *Revista de Derecho Económico*, 9(2), 101–118. <https://doi.org/10.18601/rde.v9n2.2022>

Sánchez, L. (2023). Inteligencia artificial y equidad en sistemas de decisión automatizada. *Revista Iberoamericana de Inteligencia Artificial*, 14(2), 55–72. <https://doi.org/10.4114/ria.v14i2.2023>



ISSN: 3151-8257
DOI:



Revista Internacional
MÉTRICAS
MULTIDISCIPLINARIAS

Soriano Aranz, A. (2021). Decisiones automatizadas: problemas y soluciones jurídicas. Más allá de la protección de datos. *Revista de Derecho Público: Teoría y Método*, 3, 85–127. doi: 10.37417/RPD/vol_3_2021_535.

Tahiri Moreno, J. A. (2023). El principio de presunción de falibilidad de las decisiones algorítmicas desfavorables: una nueva garantía jurídica frente a las decisiones automatizadas y el uso de sistemas de inteligencia artificial en la Administración Pública. *Revista Aragonesa de Administración Pública*, 60, 188–214.

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés