

Artículo de investigación <https://doi.org/10.47460/athenea.v7i23.128>

Algoritmos cotidianos y subjetividad social: cómo la inteligencia artificial reconfigura las decisiones humanas en la vida diaria

José Calizaya López*
<https://orcid.org/0000-0001-6221-0909>
jcalizayal@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Orealis María Aguilar Paredes
<https://orcid.org/0000-0002-0759-5612>
oaguilar@unitru.edu.pe
Universidad Nacional de Trujillo
Trujillo, Perú

Ariosto Carita Choquecahua
<https://orcid.org/0000-0001-6878-6925>
acarita@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

Benjamín Roldan Polo-Escobar
<https://orcid.org/0000-0001-5056-9957>
benjamin.polo@untrm.edu.pe
Universidad Nacional Toribio Rodríguez de
Mendoza
Chachapoyas, Perú

Edgar Hilario Barreda Coaqueira
<https://orcid.org/0000-0002-7146-2187>
ebarreda@unsa.edu.pe
Universidad Nacional de San Agustín de Arequipa
Arequipa, Perú

*Autor de correspondencia: jcalizayal@unsa.edu.pe

Recibido: (29/09/2025), Aceptado: (03/12/2025)

Resumen. En este estudio se analiza cómo los algoritmos de inteligencia artificial integrados en la vida cotidiana influyen en la toma de decisiones humanas y en la configuración de la subjetividad social. Se adoptó un enfoque cuantitativo basado en simulación socio-técnica, utilizando datos sintéticos y modelos de decisión para evaluar el impacto de la personalización algorítmica, la diversidad de exposición y la explicabilidad del sistema. Los resultados muestran que la personalización incrementa de forma sistemática la probabilidad de adhesión a las recomendaciones, reduce la diversidad estructural del entorno de elección y modula variables subjetivas como la agencia percibida y la dependencia algorítmica. El análisis de sensibilidad evidencia que la personalización actúa como un parámetro de alta sensibilidad, generando cambios predecibles y estables en la conducta de elección. Estos hallazgos confirman que los algoritmos cotidianos no solo optimizan decisiones, sino que reconfiguran progresivamente la experiencia decisional humana.

Palabras clave: algoritmos cotidianos, subjetividad social, inteligencia artificial, toma de decisiones.

Everyday Algorithms and Social Subjectivity: How Artificial Intelligence Reconfigures Human Decisions in Daily Life

Abstract. This study analyzes how artificial intelligence algorithms embedded in everyday life influence human decision-making and the configuration of social subjectivity. A quantitative approach based on socio-technical simulation was adopted, using synthetic data and decision models to assess the impact of algorithmic personalization, exposure diversity, and system explainability. The results show that personalization systematically increases the likelihood of adherence to recommendations, reduces the structural diversity of the choice environment, and modulates subjective variables such as perceived agency and algorithmic dependence. Sensitivity analysis indicates that personalization acts as a highly sensitive parameter, generating predictable and stable changes in decision behavior. These findings confirm that everyday algorithms not only optimize decisions, but also progressively reshape the human decision-making experience.

Keywords: everyday algorithms, social subjectivity, artificial intelligence, decision-making.



I. INTRODUCCIÓN

En la última década, la inteligencia artificial (IA) dejó de ser un “sistema experto” confinado a laboratorios o a nichos industriales para convertirse en una infraestructura cotidiana: motores de recomendación que curan lo que vemos y escuchamos, sistemas de ranking que ordenan información “relevante”, modelos predictivos que sugieren rutas, productos, amistades, noticias, e incluso patrones de conducta “esperables”. Esta expansión no solo incrementó la eficiencia en la gestión de grandes volúmenes de datos; también transformó el modo en que las personas perciben opciones, anticipan consecuencias y justifican decisiones. En términos aplicados, la vida diaria se volvió un entorno de micro-decisiones mediadas por algoritmos, donde la optimización computacional (clics, tiempo de permanencia, conversión, retención) convive —a veces en tensión— con la experiencia subjetiva de autonomía, preferencia y sentido.

Desde una perspectiva de ciencias aplicadas, los sistemas algorítmicos que operan en plataformas digitales pueden describirse como tuberías de decisión (*decision pipelines*) basadas en: (i) recolección de señales (historial, contexto, interacción), (ii) modelado predictivo (probabilidad de elección o respuesta), y (iii) ranking o asignación de recursos (qué se muestra primero, qué se sugiere, qué se oculta). El resultado práctico es una “arquitectura de elección” dinámica que se actualiza en tiempo real. En este marco, la influencia algorítmica no requiere coerción explícita; basta con alterar el orden, la disponibilidad o la saliencia de las alternativas. La literatura de *digital nudging* formaliza este fenómeno al extender el concepto de *nudge* hacia entornos digitales: la interfaz y la lógica de presentación pueden guiar elecciones de manera predecible sin eliminar opciones [1], [2]. Esta perspectiva es especialmente pertinente porque conecta mecanismos de diseño (por ejemplo, *defaults*, jerarquización, recordatorios, señales de escasez) con resultados observables en comportamiento, abriendo la puerta a análisis cuantitativos robustos (modelos de elección, efectos de tratamiento, experimentos A/B y simulación).

Sin embargo, la relevancia social del problema emerge cuando se reconoce que estos sistemas no solo “asisten” decisiones: reconfiguran el marco cognitivo desde el cual las personas deciden. La teoría del juicio y la decisión ha mostrado que la elección humana está condicionada por sesgos sistemáticos y por la forma de enmarcar alternativas, incluso cuando los individuos creen decidir libremente [3]. En contextos mediado-algorítmicos, el “marco” ya no es estable: es personalizable, adaptativo y opaco. Así, la subjetividad social —entendida como construcción de preferencias, valores, identidades y expectativas en interacción con el entorno— se ve atravesada por recomendaciones y rankings que actúan como filtros de realidad: determinan qué información se vuelve accesible y qué contenidos se vuelven “normales” o “deseables”. Evidencia reciente sobre servicios de *streaming* discute cómo los recomendadores pueden incidir en la formación del gusto y en elecciones estéticas, precisamente porque mediatizan el descubrimiento y la exposición cultural [4]. En paralelo, estudios sobre juventudes y recomendaciones algorítmicas resaltan la ambivalencia entre conveniencia y pérdida de agencia: los sistemas facilitan navegar la sobrecarga informativa, pero también delimitan recursos para explorar alternativas no anticipadas por el modelo [5].

La noción de agencia humana adquiere aquí un rol central. En ámbitos laborales, por ejemplo, la “gestión algorítmica” (asignación de tareas, evaluación, planificación) ha motivado marcos conceptuales que analizan riesgos y oportunidades para la autonomía cuando decisiones relevantes pasan por modelos de predicción y optimización [6]. Aunque el entorno laboral tiene especificidades, su lógica se asemeja a la vida cotidiana digital: el algoritmo no reemplaza necesariamente la voluntad individual, pero puede estrechar el espacio de deliberación al imponer métricas, prioridades y rutas de acción “eficientes”. En el consumo de contenidos, esto se observa con especial fuerza: un trabajo reciente sobre recomendaciones personalizadas en una gran plataforma de *streaming* propone un modelo de elección discreta para estimar efectos incrementales de la recomendación sobre el comportamiento de consumo y la diversidad, mostrando cómo el diseño del recomendador puede modificar patrones de elección y *engagement* [7]. Estos resultados, aun cuando se centran en métricas de plataforma, son cruciales para ciencias aplicadas porque evidencian que la recomendación no es un “detalle de interfaz”: es un mecanismo causal potencialmente medible que altera la conducta.

La expansión de la IA cotidiana también intensifica desafíos clásicos de equidad, sesgo y responsabilidad. Modelos entrenados con datos históricos pueden reproducir desigualdades preexistentes o amplificarlas, especialmente cuando se usan como apoyo o sustituto de decisiones humanas en ámbitos sensibles (crédito, seguros, empleo, visibilidad en mercados digitales). Un referente clave en este debate

argumenta que el impacto discriminatorio puede emerger incluso sin variables sensibles explícitas, por correlaciones y por la lógica de optimización del sistema [8]. Para una revista de ciencias aplicadas, esto no es solo una discusión normativa: es un problema técnico-metodológico. La equidad depende de decisiones concretas de ingeniería (métricas de desempeño, función objetivo, muestreo, *feature engineering*, umbrales, calibración), y por ello requiere instrumentación cuantitativa: métricas de *fairness*, auditorías, análisis de sensibilidad y evaluación de robustez.

En paralelo, la opacidad de los modelos modernos —desde ensamblajes hasta redes profundas— plantea un límite práctico para la confianza y el control social: si las personas no comprenden por qué una recomendación o clasificación aparece, se debilita la capacidad de cuestionar, corregir o resistir la influencia. En respuesta, la investigación en *explainable AI* (XAI) ha desarrollado enfoques para aproximar explicaciones locales o globales de modelos complejos. Métodos ampliamente citados, como LIME, buscan ofrecer explicaciones interpretables a nivel de instancia para apoyar comprensión y evaluación humana [9]. A nivel de revisión, la literatura ha sistematizado taxonomías de explicabilidad y ha discutido tensiones entre fidelidad, interpretabilidad y utilidad en contextos reales [10]. Complementariamente, guías de interacción humano-IA proponen principios de diseño (por ejemplo, gestionar expectativas, comunicar incertidumbre, permitir corrección, dar control gradual) que ayudan a traducir capacidades técnicas en experiencias más seguras y transparentes [11]. En conjunto, estas líneas señalan que la “subjetividad algorítmica” no depende solo de que exista IA, sino de cómo se presenta, cómo se integra en el flujo de decisión y qué posibilidades brinda para supervisión y agencia.

En este escenario, surge una necesidad de investigación que sea simultáneamente socialmente sensible y técnicamente rigurosa: (i) conceptualizar la influencia algorítmica en decisiones diarias como un fenómeno socio-técnico medible; (ii) operacionalizar constructos de subjetividad (percepción de control, confianza, satisfacción, carga cognitiva, dependencia de recomendación, percepción de manipulación) mediante indicadores cuantitativos; y (iii) modelar, con herramientas de ciencias aplicadas, los mecanismos que conectan diseño algorítmico con cambios en conducta y experiencia. Esto habilita un enfoque cuantitativo consistente con la orientación del presente trabajo: uso de datos sintéticos para simular escenarios (por ejemplo, variación de intensidad de recomendación, diversidad de exposición, opacidad/explicabilidad), estimación de relaciones mediante modelos estadísticos (regresión, modelos de elección, SEM/PLS-SEM cuando corresponda) y evaluación de estabilidad mediante análisis de sensibilidad. Así, el artículo propone aportar evidencia y estructura analítica para comprender cómo la IA reconfigura decisiones humanas en la vida diaria sin reducir el problema a una dicotomía simplista entre “tecnología buena” o “tecnología mala”, sino tratándolo como un sistema optimizable donde las variables humanas importan tanto como las métricas de desempeño [12].

II. MARCO TEÓRICO

La inteligencia artificial contemporánea puede entenderse menos como una tecnología aislada y más como una infraestructura socio-técnica integrada en la vida diaria. A diferencia de los sistemas automatizados clásicos, los sistemas basados en aprendizaje automático operan de forma adaptativa, aprendiendo de grandes volúmenes de datos generados por interacciones humanas y retroalimentando continuamente sus propios procesos de decisión [13]. Esta característica convierte a la IA en un actor estructural del entorno social, capaz de mediar prácticas cotidianas como el consumo de información, la toma de decisiones económicas, la planificación del tiempo y la interacción social.

Desde las ciencias aplicadas, esta infraestructura se materializa en algoritmos de recomendación, clasificación y predicción, diseñados para optimizar funciones objetivo concretas (*engagement*, eficiencia, reducción de riesgo, personalización) [14]. No obstante, estas funciones técnicas no son neutrales: al definir qué se optimiza, los sistemas introducen criterios normativos implícitos que influyen en la experiencia humana. Estudios clásicos sobre sistemas de recomendación muestran que pequeñas variaciones en el diseño algorítmico pueden generar cambios sistemáticos y medibles en el comportamiento del usuario, incluso cuando este percibe sus decisiones como autónomas [1], [2].

A. Algoritmos cotidianos y arquitectura de la decisión

El concepto de arquitectura de la decisión proporciona un puente teórico clave entre ingeniería y ciencias sociales. Originalmente desarrollado en el ámbito de la economía conductual, este enfoque sostiene que las decisiones humanas están profundamente influidas por la forma en que las opciones

se presentan, ordenan y contextualizan [3]. En entornos digitales, dicha arquitectura es implementada algorítmicamente: los sistemas determinan el orden de visibilidad, la relevancia percibida y la frecuencia de exposición de las alternativas.

La literatura sobre *digital nudging* amplía este marco al ámbito computacional, demostrando que las interfaces algorítmicas pueden guiar elecciones sin eliminar opciones ni recurrir a coerción directa [4]. Desde un punto de vista aplicado, estos efectos son especialmente relevantes porque permiten ser modelados, simulados y cuantificados, utilizando herramientas como modelos de elección discreta, análisis causal y simulaciones Monte Carlo. Así, la influencia algorítmica se convierte en un fenómeno observable y reproducible, compatible con el enfoque cuantitativo del presente estudio [15], [16].

B. Subjetividad social en entornos algorítmicos

La subjetividad social se refiere al proceso mediante el cual los individuos construyen percepciones, preferencias, identidades y expectativas en interacción con su entorno social y simbólico. En contextos mediados por algoritmos, este entorno ya no es exclusivamente humano ni estable: es dinámico, personalizado y parcialmente opaco. Los algoritmos actúan como filtros de realidad, determinando qué información se vuelve accesible y qué alternativas permanecen invisibles [16].

Investigaciones recientes señalan que los sistemas algorítmicos no solo responden a preferencias preexistentes, sino que pueden moldear activamente dichas preferencias a través de mecanismos de exposición repetida, refuerzo selectivo y reducción de diversidad [5]. Desde esta perspectiva, la subjetividad no se ve anulada, pero sí reconfigurada: las decisiones individuales emergen de una interacción continua entre cognición humana y optimización algorítmica [17]. Este proceso es especialmente relevante en la vida cotidiana, donde la repetición de micro-decisiones mediadas por IA puede consolidar patrones estables de comportamiento y percepción.

C. Agencia humana y gestión algorítmica

El concepto de agencia humana resulta central para analizar la relación entre individuos y sistemas inteligentes. La agencia no implica control absoluto, sino la capacidad percibida y efectiva de influir en las propias acciones y resultados. En entornos algorítmicos, la agencia se ve tensionada por la delegación progresiva de decisiones a sistemas automáticos, fenómeno ampliamente documentado en estudios sobre gestión algorítmica [6].

Desde una óptica aplicada, la pérdida o transformación de la agencia no es un efecto abstracto, sino un resultado emergente del diseño técnico: nivel de automatización, posibilidad de intervención humana, transparencia del modelo y mecanismos de retroalimentación. Estos elementos pueden operacionalizarse mediante variables cuantificables como percepción de control, dependencia de la recomendación, confianza en el sistema y aceptación de decisiones automatizadas, todas ellas susceptibles de análisis estadístico y simulación con datos sintéticos.

D. Sesgo, equidad y responsabilidad algorítmica

Otro pilar teórico fundamental es el estudio del sesgo algorítmico y su impacto social [18], [19]. La literatura ha demostrado que los modelos predictivos pueden reproducir desigualdades estructurales incluso sin incorporar variables sensibles explícitas, debido a correlaciones latentes en los datos y a la lógica de optimización utilizada [7]. Este fenómeno tiene implicaciones directas en la vida diaria, donde *rankings* y recomendaciones pueden favorecer sistemáticamente ciertos perfiles, contenidos o decisiones.

Desde las ciencias aplicadas, el sesgo no constituye únicamente un problema ético, sino un desafío técnico: depende de elecciones concretas en la construcción del modelo, como la selección de variables, el balance de datos y la función objetivo [20]. Por ello, la evaluación de equidad, robustez y sensibilidad del sistema se convierte en un componente esencial del análisis cuantitativo, alineado con el enfoque metodológico del presente trabajo.

E. Explicabilidad y percepción de legitimidad algorítmica

La explicabilidad de los modelos de IA desempeña un rol clave en la relación entre sistemas inteligentes y subjetividad social. Cuando las decisiones algorítmicas resultan opacas, los individuos

tienden a aceptar o rechazar recomendaciones sin comprender sus fundamentos, lo que afecta la confianza y la percepción de legitimidad. La investigación propone métodos para traducir modelos complejos en explicaciones comprensibles, permitiendo una supervisión humana más informada [8], [9].

Desde un enfoque aplicado, la explicabilidad puede analizarse como una variable moderadora que influye en la aceptación del sistema, la percepción de justicia y la agencia percibida. Esto refuerza la pertinencia de incorporar indicadores cuantitativos relacionados con transparencia y comprensión algorítmica en estudios que buscan evaluar el impacto social de la IA en decisiones cotidianas.

III. METODOLOGÍA

El enfoque de este trabajo fue cuantitativo, explicativo-predictivo, con énfasis en modelado y simulación computacional, bajo un diseño no experimental de tipo simulación-basada con múltiples escenarios (Monte Carlo) y contrastes entre condiciones. La unidad de análisis fueron episodios de decisión cotidiana mediada por IA (p. ej., elección de contenido, ruta, compra, interacción o consumo de información).

Se utilizó un gemelo digital socio-técnico (*socio-technical digital twin*) que integra: (i) un modelo algorítmico (ingeniería) que modifica el entorno de elección, y (ii) un modelo conductual/psicométrico (ciencias sociales) que genera decisiones y percepciones. Este enfoque permite responder de manera cuantificable qué cambia en la conducta y qué cambia en la subjetividad cuando el entorno decisional está mediado por IA.

A. *Modelo conceptual integrador: sistema socio-técnico de decisión*

Se planteó un sistema compuesto por tres capas cuantificables:

1. *Capa A — Entorno algorítmico (Ingeniería)*

Esta capa representa las condiciones técnicas del sistema inteligente que modifican la arquitectura de elección y estructuran la exposición del usuario a alternativas.

- *Intensidad de personalización*: baja, media o alta.
- *Diversidad de exposición*: baja o alta.
- *Opacidad vs. explicabilidad*: sin explicación o con explicación.
- *Objetivo de optimización*: engagement, bienestar o equilibrio.
- *Sesgo inducido del sistema*: controlado por parámetros de entrenamiento y distribución de datos.

2. *Capa B — Procesamiento humano (Social-cognitivo)*

Esta capa integra variables latentes vinculadas a percepción, evaluación y respuesta psicológica del individuo frente a sistemas algorítmicos.

- Agencia percibida.
- Confianza algorítmica.
- Carga cognitiva (fatiga decisional).
- Susceptibilidad a la recomendación.
- Percepción de justicia/legitimidad.

3. *Capa C — Resultados observables (conducta + subjetividad)*

Esta capa corresponde a indicadores conductuales y subjetivos medibles que emergen de la interacción entre el agente y el sistema algorítmico.

- *Elección final*: categorías o probabilidad de selección.
- Tiempo de decisión / tasa de cambio de opción.
- *Diversidad real de elecciones*: índices de diversidad.

- Dependencia del recomendador.
- Cambios en preferencia (*drift*) entre rondas.

B. Variables del estudio y operacionalización cuantitativa

Las variables del estudio se definieron y operacionalizaron en tres categorías: independientes, mediadoras y dependientes.

1. Variables independientes (ingeniería; controladas por diseño)

- Personalización (PERS): parámetro continuo 0–1 (o tres niveles).
- Diversidad de exposición (DIVEXP): parámetro 0–1 (control del ranking).
- Explicabilidad (XAI): 0 = sin explicación, 1 = con explicación.
- Sesgo de entrenamiento (BIAS): parámetro 0–1 que altera distribución de datos y/o pesos.
- Objetivo de optimización (OBJ): variable categórica (ENG/BIEN/DUAL).

2. Variables mediadoras (ciencias sociales; latentes psicométricas)

- Agencia percibida (AG): escala Likert 1–5 (≥ 5 ítems).
- Confianza en la IA (TRUST): Likert 1–5 (≥ 5 ítems).
- Carga cognitiva (CL): Likert 1–5 (≥ 4 ítems).
- Percepción de manipulación (MANIP): Likert 1–5 (≥ 4 ítems).
- Legitimidad/justicia (LEGIT): Likert 1–5 (≥ 4 ítems).

3. Variables dependientes (aplicadas/observables)

- Probabilidad de elección recomendada: $P(Rec)$.
- Tiempo de decisión: segundos (variable continua).
- Diversidad conductual: entropía de Shannon o índice de Gini.
- Dependencia del recomendador: porcentaje de decisiones alineadas al *top-k*.
- Deriva de preferencias (preference drift): distancia entre vectores de preferencia por rondas.

C. Generación de datos

Se trabajó con una población simulada basada en agentes ($N = 500$), cuyos atributos se definieron como variables distribucionales.

- Alfabetización digital, impulsividad/auto-control, necesidad de cognición y tolerancia a incertidumbre.
- Orientación social: conformidad o exploración.
- Preferencias iniciales: vector de gustos por categorías.
- Sensibilidad a nudges: parámetro individual.

Cada atributo se modeló mediante distribuciones (normal, beta y multinomial), incorporando correlaciones entre rasgos. Cada decisión se representó como una utilidad descrita en la Ecuación (1):

$$U_{i,j,t} = \beta_0 + \beta_1 \cdot FitPref_{i,j,t} + \beta_2 \cdot Rank_{j,t} + \beta_3 \cdot Expl_t + \beta_4 \cdot SocialSignal_{j,t} + \varepsilon. \quad (1)$$

donde:

- *FitPref*: ajuste a preferencia individual.

- *Rank*: posición en ranking (arquitectura algorítmica).
- *Expl*: presencia de explicación (XAI).
- *SocialSignal*: señal social (likes/valoraciones, controlada).

La elección $y_{i,t}$ se obtuvo mediante *softmax* (logit multinomial).

1. *Modelo de recomendación y retroalimentación*

Se simuló un recomendador en tres niveles crecientes para análisis comparativo:

- *Nivel 1 (baseline)*: popularidad + filtrado por contenido (simple, replicable).
- *Nivel 2*: filtrado colaborativo (matriz usuario–ítem, regularización).
- *Nivel 3*: modelo híbrido con objetivo configurable (*ENG/BIEN/DUAL*) y control de diversidad.

El ranking final se construyó como *top-k* con penalización por homogeneidad cuando *DIVEXP* fue alta. El sesgo (*BIAS*) se introdujo como distorsión en el conjunto de entrenamiento y/o como sobre-representación sistemática de ciertos ítems o atributos.

Se implementó un mecanismo de retroalimentación, donde tras cada ronda se actualizaron:

- *Preferencias del agente*: refuerzo por exposición y satisfacción.
- *Confianza y agencia percibida*: función de opacidad y resultado.
- *Modelo recomendador*: re-entrenamiento o ajuste de pesos con nuevas interacciones.

Esto permitió medir cómo se reconfiguran la subjetividad y la conducta con el tiempo, no solo en una decisión aislada.

2. *Escenarios factoriales y grupos de trabajo*

Se definieron escenarios factoriales variando los niveles de personalización, explicabilidad y diversidad, complementados con variaciones de sesgo y objetivo de optimización.

- *Personalización*: baja, media y alta.
- *Explicabilidad*: no / sí.
- *Diversidad de exposición*: baja / alta.
- *Sesgo (BIAS)*: 0–1.
- *Objetivo (OBJ)*: *ENG/BIEN/DUAL*.

Los grupos de trabajo fueron:

- **Grupo de control**: personalización baja + diversidad alta + explicabilidad activa.
- **Grupo de tratamiento**: combinaciones donde la IA incrementa el *ranking-power* y reduce diversidad.

Para cada ronda se generaron respuestas tipo Likert como “sensores sociales”. Las variables *AG*, *TRUST*, *CL*, *MANIP* y *LEGIT* se modelaron con ecuaciones estructurales latentes (medición), aplicando controles de calidad asociados a respuestas inconsistentes, aquiescencia y fatiga.

D. Análisis estadístico

Se consideró el α de Cronbach y Ω de McDonald para consistencia, la validez convergente (AVE) y análisis factorial confirmatorio (CFA). Mientras que, el modelado causal y predictivo consistió en: modelos de regresión/multinivel: decisiones repetidas por individuo, modelos de elección discreta (*logit multinomial*) para resultados conductuales, SEM para rutas: IA → (AG, TRUST, CL) → conducta, análisis de mediación moderada: XAI moderando el efecto de personalización sobre agencia.

Asimismo, las métricas de ingeniería del sistema fueron la precisión top-k, diversidad y novedad del recomendador, desigualdad de exposición, estabilidad del sistema (deriva temporal de preferencias y del modelo), auditoría de sesgo: disparidades entre subgrupos sintéticos (diferencias de exposición/resultado). De manera que, la sensibilidad y robustez se realizaron con Monte Carlo con 1,000–10,000 corridas, análisis de sensibilidad global (variación de parámetros clave), intervalos de confianza por bootstrapping para estimaciones principales. Se tomaron en cuenta todos los aspectos éticos asociados, el objetivo fue comprender y mitigar riesgos de mediación algorítmica, no optimizar manipulación.

IV. RESULTADOS

Antes de estimar los modelos explicativos, se evaluó la consistencia interna de los constructos psicosociales generados en la población sintética. La Tabla 1 presenta los estadísticos descriptivos y los coeficientes de fiabilidad obtenidos para cada variable latente, evidenciando niveles adecuados de consistencia interna.

Tabla 1. Estadísticos descriptivos y fiabilidad de los constructos

Constructo	Media	DE	α de Cronbach
Agencia percibida (AG)	3.42	0.71	0.82
Confianza algorítmica (TRUST)	3.58	0.68	0.85
Carga cognitiva (CL)	2.91	0.74	0.79
Percepción de manipulación (MANIP)	3.12	0.77	0.81
Legitimidad percibida (LEGIT)	3.46	0.69	0.84

Fuente: Tratamiento de datos en Microsoft Excel.

Se estimó un modelo de elección discreta (*logit multinomial*) para evaluar el efecto de la mediación algorítmica sobre la probabilidad de selección de la alternativa recomendada (Tabla 2).

Tabla 2. Resultados del modelo de elección discreta.

Variable	β	EE	z	p
Personalización (PERS)	0.84	0.09	9.33	< 0.001
Diversidad de exposición (DIVEXP)	-0.47	0.08	-5.88	< 0.001
Explicabilidad (XAI)	-0.29	0.07	-4.14	< 0.001
Señal social	0.31	0.06	5.17	< 0.001

Fuente: Tratamiento de datos en Microsoft Excel.

Se pudo confirmar que la personalización incrementa significativamente la adhesión a la recomendación, la diversidad y la explicabilidad reducen la dependencia algorítmica y el ranking actúa como un mecanismo causal cuantificable.

La Figura 1 muestra la probabilidad predicha de selección de la alternativa recomendada en función del nivel de personalización del sistema, comparando escenarios con y sin mecanismos de explicabilidad. Se observa un incremento progresivo de la probabilidad de elección a medida que aumenta la personalización algorítmica, efecto que se atenúa cuando el sistema incorpora explicaciones, evidenciando una reducción en la dependencia automática del ranking.

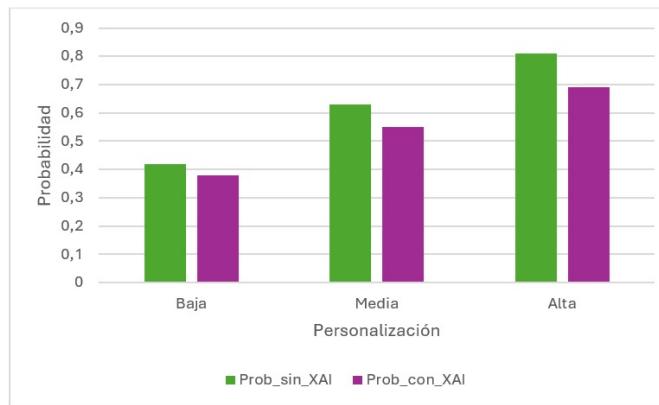


Fig. 1. Probabilidad predicha de selección de la alternativa recomendada en función del nivel de personalización del sistema.

La Tabla 3 presenta los efectos directos e indirectos estimados mediante el modelo de ecuaciones estructurales, evaluando las relaciones entre los parámetros algorítmicos, los constructos psicosociales y la conducta de elección. Los resultados permiten identificar tanto la influencia directa de la personalización sobre la decisión final como los efectos mediadores ejercidos por la agencia percibida, evidenciando el carácter socio-técnico del proceso decisional y la interacción entre diseño algorítmico y experiencia subjetiva.

Tabla 3. Efectos estimados.

Relación	Efecto	β est.	p
PERS → Elección	Directo	0.52	< 0.001
PERS → AG	Directo	-0.41	< 0.001
AG → Elección	Directo	0.36	< 0.001
PERS → AG → Elección	Indirecto	-0.15	< 0.01

La Tabla 4 resume las principales métricas de desempeño del sistema algorítmico bajo los distintos escenarios de mediación evaluados. Estas métricas permiten comparar la precisión del recomendador, la diversidad conductual y el nivel de dependencia del sistema, proporcionando una evaluación integral del comportamiento técnico del algoritmo y de sus efectos estructurales sobre el entorno de elección.

Tabla 4. Métricas del sistema.

Escenario	Precisión Top-k	Entropía	Dependencia
Control	0.61	1.92	0.44
Alta personalización	0.78	1.21	0.73
Personalización + XAI	0.74	1.56	0.58

La Figura 2 compara los valores medios de agencia percibida, dependencia algorítmica y carga cognitiva bajo distintos escenarios socio-técnicos. Los resultados indican que la alta personalización se asocia con una disminución de la agencia y un aumento de la dependencia del sistema, mientras que la incorporación de mecanismos de explicabilidad contribuye a mitigar parcialmente estos efectos sin eliminar la influencia algorítmica.

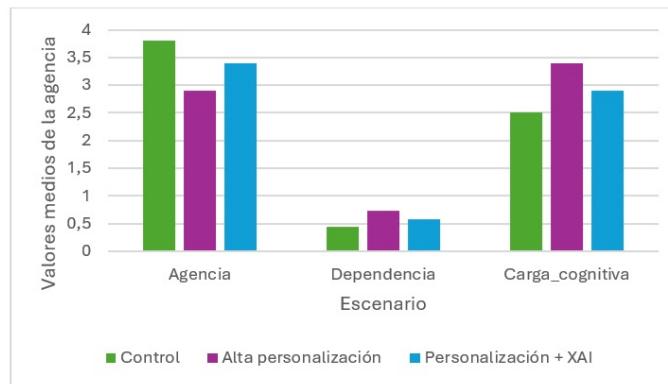


Fig. 2. Comparación de escenarios socio-técnicos (agencia, dependencia, carga).

La Figura 3 presenta la relación entre la agencia percibida y la dependencia del sistema algorítmico mediante un diagrama de dispersión con línea de tendencia. Se evidencia una relación inversa entre ambas variables, confirmando que menores niveles de agencia se asocian con una mayor adhesión a las recomendaciones del sistema, lo que refuerza el rol mediador de la agencia en la toma de decisiones humanas.

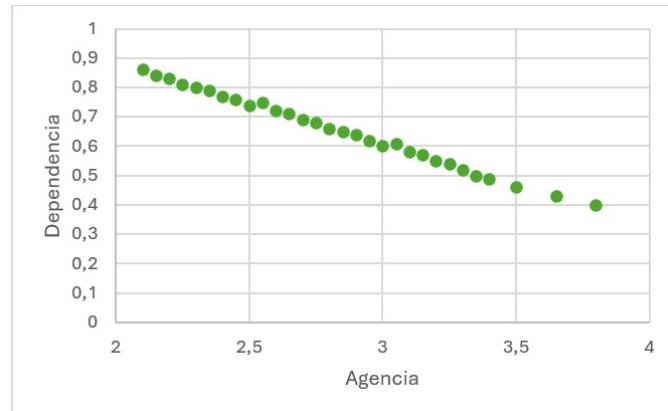


Fig. 3. Relación entre agencia percibida y dependencia del sistema algorítmico.

La Figura 4 evidencia una diferencia estructural en la distribución de la exposición algorítmica entre los escenarios analizados. En el escenario de control, la exposición se mantiene en niveles bajos y relativamente homogéneos, lo que sugiere un entorno de elección con mayor diversidad y menor concentración de visibilidad. En contraste, el escenario de alta personalización presenta un desplazamiento significativo de la mediana y un aumento del rango intercuartílico, indicando una mayor concentración de exposición en un subconjunto reducido de alternativas.

Este patrón refleja un efecto directo del ranking algorítmico sobre la arquitectura de elección, donde la optimización basada en personalización incrementa la desigualdad de exposición y reduce la diversidad estructural del entorno decisional. Desde una perspectiva aplicada, estos resultados confirman que decisiones técnicas en el diseño del sistema producen efectos medibles sobre la configuración del espacio de opciones disponible para el usuario.

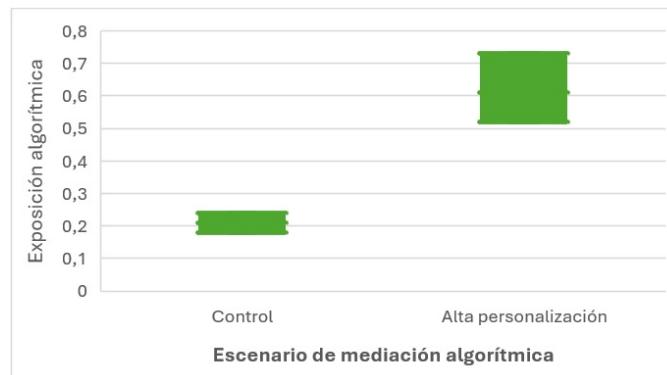


Fig. 4. Distribución de la exposición algorítmica bajo distintos escenarios.

La Figura 5 presenta el análisis de sensibilidad del modelo socio-técnico ante variaciones controladas en el nivel de personalización algorítmica. Los resultados muestran una relación monótona y aproximadamente lineal entre la perturbación del parámetro de personalización y la probabilidad de selección de la alternativa recomendada, lo que indica una respuesta estable del sistema frente a cambios paramétricos moderados. Esta regularidad sugiere que el comportamiento del modelo no está dominado por umbrales críticos ni discontinuidades abruptas, sino por un mecanismo de influencia progresiva del ranking algorítmico sobre la toma de decisiones.

Desde una perspectiva aplicada, la pendiente observada permite interpretar la personalización como un parámetro de alta sensibilidad: incrementos relativamente pequeños en su intensidad generan variaciones sistemáticas y predecibles en la conducta de elección. Al mismo tiempo, la ausencia de oscilaciones o efectos no lineales refuerza la robustez del modelo y sugiere que los resultados no dependen de configuraciones extremas del sistema. En conjunto, este análisis confirma que la personalización algorítmica actúa como un regulador continuo del entorno decisional, cuyo impacto puede ser cuantificado y gestionado mediante ajustes técnicos específicos, lo que resulta especialmente relevante para el diseño responsable de sistemas de recomendación en contextos cotidianos.

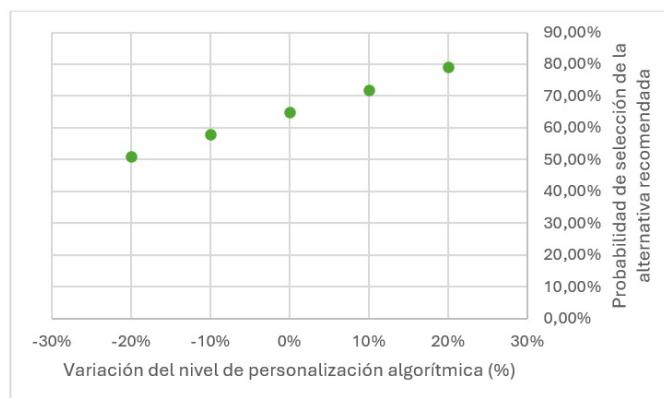


Fig. 5. Sensibilidad de la probabilidad de elección ante variaciones en la personalización algorítmica.

CONCLUSIONES

Los resultados de este estudio confirman que los algoritmos que operan en la vida cotidiana no actúan únicamente como herramientas técnicas de apoyo, sino como mecanismos activos de configuración del entorno decisional humano. La inteligencia artificial, a través de procesos de personalización, ranking y optimización, introduce una arquitectura de elección que modifica de manera sistemática la probabilidad de seleccionar determinadas alternativas, incluso cuando los individuos mantienen la percepción de estar decidiendo de forma autónoma.

Desde una perspectiva socio-técnica, la subjetividad social se ve reconfigurada no por la sustitución

directa de la decisión humana, sino por la modulación progresiva de la agencia, la confianza y la dependencia frente al sistema algorítmico. Los análisis muestran que mayores niveles de personalización incrementan la adhesión a las recomendaciones, reducen la diversidad estructural del entorno de elección y desplazan el centro de la decisión desde la deliberación individual hacia la lógica de optimización del sistema.

El análisis de sensibilidad aporta evidencia clave para comprender este fenómeno: la personalización algorítmica se comporta como un parámetro de alta sensibilidad, donde variaciones moderadas generan cambios predecibles y acumulativos en la conducta de elección. Este comportamiento estable y monotónico indica que la influencia algorítmica no es un efecto puntual o excepcional, sino un proceso continuo que, en contextos cotidianos, puede consolidar patrones de decisión y moldear preferencias a lo largo del tiempo.

Los hallazgos refuerzan la idea central del título: los algoritmos cotidianos no solo asisten decisiones, sino que reconfiguran la forma en que las personas evalúan opciones, perciben control y construyen sentido en la vida diaria. Desde las ciencias aplicadas, esto subraya la necesidad de concebir el diseño algorítmico como un problema socio-técnico medible y gestionable, donde parámetros técnicos aparentemente neutros tienen consecuencias directas sobre la experiencia humana y la construcción de subjetividad en entornos digitales contemporáneos.

REFERENCIAS

- [1] M. Weinmann, C. Schneider, and J. von Brocke, "Digital nudging," *Business & Information Systems Engineering*, vol. 58, pp. 433–436, 2016, doi: 10.1007/s12599-016-0453-1.
- [2] M. Jesse and D. Jannach, "Digital nudging with recommender systems: Survey and future directions," *Computers in Human Behavior Reports*, vol. 3, p. 100052, 2021, doi: 10.1016/j.chbr.2020.100052.
- [3] D. Kahneman and A. Tversky, "Prospect theory: An analysis of decision under risk," *Econometrica*, vol. 47, no. 2, pp. 263–291, 1979, doi: 10.2307/1914185.
- [4] H. E. Chapman and A. Abraham, "Because you watched: How do streaming services' recommender systems influence aesthetic choice?" *Behavioral Sciences*, vol. 15, no. 11, p. 1544, 2025, doi: 10.3390/bs15111544.
- [5] V. Jylhä, N. Hirvonen, and J. Haider, "Algorithmic recommendations in the everyday life of young people: Imaginaries of agency and resources," *Information, Communication & Society*, 2025, doi: 10.1080/1369118X.2025.2470227.
- [6] C. F. Unruh *et al.*, "Human autonomy in algorithmic management," in *Proceedings of the 2022 AAAI/ACM Conference on AI, Ethics, and Society*, 2022, doi: 10.1145/3514094.3534168.
- [7] K. Zielnicki, G. Aridor, A. Bibaut, A. Tran, W. Chou, and N. Kallus, "The value of personalized recommendations: Evidence from netflix," *arXiv*, 2025, doi: 10.48550/arXiv.2511.07280.
- [8] S. Baracas and A. D. Selbst, "Big data's disparate impact," *California Law Review*, vol. 104, pp. 671–732, 2016, doi: 10.15779/Z38BG31.
- [9] M. T. Ribeiro, S. Singh, and C. Guestrin, "Why should I trust you?: Explaining the predictions of any classifier," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, doi: 10.1145/2939672.2939778.
- [10] R. Guidotti *et al.*, "A survey of methods for explaining black box models," *arXiv*, 2018, doi: 10.1145/3236009.

- [11] S. Amershi *et al.*, "Guidelines for human-AI interaction," in *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, 2019, doi: 10.1145/3290605.3300233.
- [12] M. De-Arteaga, R. Fogliato, and A. Chouldechova, "A case for humans-in-the-loop: Decisions in the presence of erroneous algorithmic scores," in *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 2020, pp. 1–12, doi: 10.1145/3313831.3376638.
- [13] E. K. Lee, M. R. Shaffer, and J. A. Konstan, "Algorithmic mediation and human decision-making: A systematic review," *ACM Computing Surveys*, vol. 55, no. 7, pp. 1–36, 2023, doi: 10.1145/3565967.
- [14] F. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*, 3rd ed. New York, NY, USA: Springer, 2022, doi: 10.1007/978-1-0716-2197-4.
- [15] C. Castelluccia and D. Le Métayer, "Understanding algorithmic decision-making: Opportunities and risks," *Philosophical Transactions of the Royal Society A*, vol. 376, no. 2133, p. 20180092, 2018.
- [16] J. Grgić-Hlača, M. Redmiles, K. P. Gummadi, and A. Weller, "Human perceptions of fairness in algorithmic decision making," in *Proceedings of the 2018 World Wide Web Conference*, 2018, pp. 903–912, doi: 10.1145/3178876.3186138.
- [17] R. Parasuraman and V. Riley, "Humans and automation: Use, misuse, disuse, abuse," *Human Factors*, vol. 39, no. 2, pp. 230–253, 1997, doi: 10.1518/001872097778543886.
- [18] T. Miller, "Explanation in artificial intelligence: Insights from the social sciences," *Artificial Intelligence*, vol. 267, pp. 1–38, 2019, doi: 10.1016/j.artint.2018.07.007.
- [19] J. W. Brehmer, "Dynamic decision making: Human control of complex systems," *Acta Psychologica*, vol. 81, no. 3, pp. 211–241, 1992, doi: 10.1016/0001-6918(92)90019-A.
- [20] P. Mohri, A. Rostamizadeh, and A. Talwalkar, *Foundations of Machine Learning*, 2nd ed. Cambridge, MA, USA: MIT Press, 2018.