

UCUENCA

Universidad de Cuenca

Facultad de Ciencias Económicas y Administrativas

Carrera de Economía

Simulación del Descuento Hiperbólico mediante Grandes Modelos de Lenguaje (LLMs): Desarrollo y evaluación de intervenciones para mitigar la inconsistencia temporal en decisiones económicas

Trabajo de titulación previo a
la
obtención del título de
Economista

Autor:

Diego Isaac Peñaloza Guamán

Directora:

Joselin Katerine Segovia Sarmiento

ORCID: 0000-0002-3895-3814

Cuenca, Ecuador

2026-06-15

Resumen

El presente trabajo desarrolla y evalúa una estrategia de simulación basada en agentes para estudiar y mitigar el descuento hiperbólico, empleando grandes modelos de lenguaje como unidades de decisión e intervenciones de Pensamiento Episódico del Futuro (EFT). El objeto central es el grado de sesgo presente de cada agente —su inconsistencia temporal, representada por el parámetro β del modelo cuasi-hiperbólico— y la capacidad de un mecanismo adaptativo de intervención para modificarlo. El programa emplea perfiles anclados en la literatura empírica y un número de simulaciones determinado por una regla de parada por convergencia. Sobre la base en español neutro (290 agentes, 4.350 decisiones), el EFT reduce el sesgo presente ($\hat{\gamma} +0,146$; $p < 0,0001$), con un efecto que crece con la severidad del perfil y una única variante eficaz, la de pérdida y arrepentimiento anticipado; el resultado se replica en español ecuatoriano e inglés. El componente central es un sistema adaptativo que almacena estrategias, aprende de sus resultados y genera EFT personalizado: eleva la paciencia desde un fuerte presentismo ($\beta \approx 0,05$) hasta valores altos ($\beta \approx 1,0$) y sostiene ese cambio a lo largo de las sesiones. En conjunto, los resultados aportan evidencia convergente para las tres hipótesis dentro del entorno simulado, lo que sugiere que el sistema puede operar como una etapa de prevalidación previa a estudios con participantes humanos.

Palabras clave del autor: *descuento hiperbólico, grandes modelos de lenguaje, economía conductual, inconsistencia temporal, agentes simulados*

Códigos JEL: C63, D91, C45, D87, O33.



El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Cuenca ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por la propiedad intelectual y los derechos de autor.

Repositorio Institucional: <https://dspace.ucuenca.edu.ec/>

Abstract

This work develops and evaluates a computational experimental framework to study and mitigate hyperbolic discounting using simulated agents based on large language models and Episodic Future Thinking (EFT) interventions. The central object is each agent's degree of present bias (its temporal inconsistency, represented by the parameter β of the quasi-hyperbolic model) and the capacity of an intelligent system to modify it. The program uses profiles anchored in ranges documented in the empirical literature and a number of simulations determined by a convergence stopping rule rather than a fixed quota. On the neutral-Spanish baseline (290 agents, 4,350 decisions), EFT reduces present bias ($\hat{\gamma} +0.146$; $p < 0.0001$), with an effect that grows with profile severity ($\Delta\beta +0.12$ moderate, $+0.31$ severe) and a single effective variant, anticipated loss and regret. The effect replicates in Ecuadorian Spanish and English. The core of the thesis is the Intelligent Intervention System, with strategy memory, learning and personalized EFT generation: the system learns without supervision which intervention to use, raises patience from strong present bias ($\beta \approx 0.05$) to high values ($\beta \approx 1.0$) when it intervenes conversationally and iteratively, and sustains that change across successive sessions through persistent memory (group \times session interaction significant by GEE). The results provide convergent evidence for the three hypotheses within the simulated environment and position the system as a prevalidation platform prior to studies with human participants.

Author Keywords: *hyperbolic discounting, large language models, behavioral economics, temporal inconsistency, synthetic agents*

JEL Codes: C63, D91, C45, D87, O33.



The content of this work corresponds to the right of expression of the authors and does not compromise the institutional thinking of the University of Cuenca, nor does it release its responsibility before third parties. The authors assume responsibility for the intellectual property and copyrights.

Institutional Repository: <https://dspace.ucuenca.edu.ec/>

Índice de contenido

1. Introducción	8
2. Revisión de literatura y estado del arte	10
2.1 Fundamentos teóricos del descuento hiperbólico	10
2.2 LLMs como simuladores conductuales: capacidades y límites	10
2.3 Arquitecturas de agentes y la amnesia temporal	11
2.4 Intervenciones conductuales para el descuento temporal.....	11
2.5 Identificación de brechas en la literatura.....	12
3. Marco teórico	13
3.1 El modelo cuasi-hiperbólico ($\beta - \delta$) como métrica de análisis.....	13
3.2 El sistema de intervención adaptativo.....	13
3.2.1 Detección de Eventos Críticos (EM-LLM): el momento de la intervención.....	13
3.2.2 Ponderación de Relevancia (TempSAL): la calidad de la intervención	14
3.2.3 Evolución de Estrategias (A-MEM): el aprendizaje del sistema	14
3.3 EFT dinámico como mecanismo de intervención.....	14
3.4 LLMs como unidades simuladas de decisión: validez del marco	14
4. Metodología	16
4.1 Enfoque metodológico: simulación basada en agentes	16
4.2 Diseño de los agentes simulados	16
4.3 Diseño experimental.....	17
4.4 Variables	18
Variable dependiente	18
Variables independientes (tratamientos)	18
Variables de control y moderadoras.....	18
4.5 Procedimiento experimental: el sistema adaptativo	19
4.6 Arquitectura tecnológica y tratamiento de datos	19
4.7 Uso de los datos para responder las preguntas de investigación	19
4.8 Estrategia de identificación en simulación	20

4.9 Especificación econométrica	20
4.10 Contraste de hipótesis	21
4.11 Análisis cuantitativo y cualitativo.....	22
4.12 Calibración externa y comparación con referencias humanas	22
4.13 Pruebas de robustez.....	22
5. Resultados.....	24
5.1 Calibración del marco de simulación (línea base).....	24
5.2 Efectividad general de las intervenciones EFT (H3)	25
5.3 Heterogeneidad del efecto por perfil conductual (H1)	26
5.4 El sistema adaptativo y la transformación del β (H2)	27
5.5 Robustez: validación entre culturas y efecto del formato	31
6. Discusión y conclusiones	32
7. Alcance y limitaciones del estudio.....	33
8. Aplicaciones prácticas y recomendaciones	34
9. Referencias.....	36
10. Anexos.....	43
ANEXO A. ARQUITECTURA DEL SISTEMA DE INTERVENCIÓN INTELIGENTE	43
ANEXO B. EVALUACIÓN DEL SISTEMA INTELIGENTE Y EL CAMBIO DEL β	44
ANEXO C. ANÁLISIS CUALITATIVO DE LAS INTERVENCIONES GENERADAS.....	46

Índice de figuras

Figura 1. Distribución del parámetro β por perfil (grupo de control, español neutro). Cada punto es un agente; el punto grande, la media del subgrupo.	25
Figura 2. Tasa de reversión de la decisión por variante del preámbulo EFT (perfil moderado, ítem por ítem).....	26
Figura 3. Puntuación final de A-MEM por estrategia (perfil moderado; arranque en empate, 0,5).	27
Figura 4. Parámetro β posterior por condición (perfil moderado): del control ($\beta \approx 0,05$) a las condiciones de intervención ($\beta \approx 1,0$).....	28
Figura 5. Bucle conversacional: estrategia que induce la reversión (izquierda) y número de turnos hasta la decisión paciente (derecha).	29
Figura 6. Decisiones demoradas previas a la intervención por sesión: tratamiento frente a control (perfil moderado, memoria persistente).	30

Índice de tablas

Tabla 1. Calibración del marco de simulación: parámetro β estimado por perfil (grupo de control, español neutro). 24

1. Introducción

El descuento hiperbólico es uno de los sesgos cognitivos más extendidos y costosos para el bienestar económico individual. A diferencia del descuento exponencial, que presupone consistencia temporal, describe la tendencia a sobrevalorar las recompensas inmediatas de forma desproporcionada. Este patrón resulta especialmente relevante en economías como la ecuatoriana, donde el crédito de consumo opera a tasas elevadas (Banco Central del Ecuador, 2026) y una porción amplia del empleo es informal (Instituto Nacional de Estadística y Censos, 2025). Sus consecuencias están documentadas en el ahorro y la jubilación (Laibson, 1997), en la salud (el descuento elevado se asocia de forma robusta con la obesidad (Amlung, Petker, Jackson, Balodis, & MacKillop, 2016) y las adicciones (Amlung, Vedelago, Acker, Balodis, & MacKillop, 2017)) y en el endeudamiento excesivo (Frederick, Loewenstein, & O'Donoghue, 2002). Aunque la economía conductual ha caracterizado extensamente este sesgo y ha propuesto intervenciones como el Pensamiento Episódico del Futuro (EFT) (Atance & O'Neill, 2001; Ye, et al., 2022; Colton, Connors, Mahlberg, & Verdejo-Garcia, 2024), persiste una brecha: la carencia de herramientas experimentales escalables y de bajo costo para probar y refinar esas intervenciones de manera dinámica y adaptativa, pues los experimentos con sujetos humanos resultan costosos y de ejecución prolongada, y enfrentan dificultades para alcanzar el tamaño muestral que exigen una potencia estadística adecuada y una heterogeneidad suficiente de los participantes (Almaatouq, et al., 2021; Anthis, et al., 2025; Slumbers, Leibo, & Janssen, 2025).

Los grandes modelos de lenguaje (LLMs) ofrecen una vía para reducir esa brecha. Al reproducir patrones de razonamiento y decisión humanos, permiten simular comportamiento económico a gran escala y bajo costo, sin las restricciones de orden logístico, los tiempos prolongados ni las consideraciones éticas que acarrearán los experimentos con personas. A esto se suma una segunda razón, dado que la propia tecnología forma parte del problema: los sistemas de inteligencia artificial del comercio electrónico y el marketing digital explotan, de forma inadvertida o deliberada, el descuento hiperbólico para inducir decisiones de gasto inmediato y perpetuar elecciones económicas subóptimas (Calo, 2014; Yeung, 2017; Mathur, et al., 2019). Esta capacidad de manipulación se intensifica con los propios LLMs, cuya persuasión iguala o supera a la humana, sobre todo cuando personalizan el mensaje a partir de datos del usuario (Salvi, Horta Ribeiro, Gallotti, & West, 2025). Por tanto, estudiar y mitigar el sesgo con las mismas herramientas capaces de amplificarlo adquiere especial relevancia.

No obstante, el uso de los LLMs como simuladores conductuales enfrenta una limitación de fondo, que en este trabajo se denomina amnesia temporal: los modelos operan en el momento de la instrucción de entrada, sin una noción intrínseca del tiempo ni un registro que

se conserve entre interacciones sucesivas. Esto restringe las simulaciones a experimentos de una sola medición e impide estudiar cómo persisten los sesgos y cómo varía la eficacia de las intervenciones a lo largo de múltiples decisiones. (Wang, et al., 2024a)

Este trabajo aborda dicha brecha mediante el desarrollo y la evaluación de un marco metodológico computacional que supera la amnesia temporal a través de agentes generativos dotados de memoria. El marco incorpora memoria episódica y memoria agéntica, junto con un componente de aprendizaje reflexivo, lo que permite refinar la intervención EFT sin recurrir a participantes humanos y sin las restricciones temporales de los diseños convencionales (Fountas, et al., 2025; Xu, et al., 2025; Shinn, et al., 2023). La contribución principal es de orden metodológico antes que teórico: una herramienta funcional y evaluada dentro del entorno simulado para la economía conductual computacional (Chen, Kao, & Venkatachalam, 2017), un campo que extiende la economía computacional basada en agentes (Tsfatsion, 2006) y la ciencia social computacional (Lazer, et al., 2009) mediante agentes generativos.

El objetivo general es diseñar y poner a prueba intervenciones de Pensamiento Episódico del Futuro (EFT) simuladas mediante LLMs para mitigar el descuento hiperbólico. Los objetivos específicos son: (i) construir agentes con perfiles diferenciados y memoria persistente; (ii) implementar el sistema de intervención adaptativo con detección de eventos críticos, ponderación temporal y aprendizaje A-MEM; y (iii) evaluar su eficacia frente a controles, a lo largo del tiempo, entre modelos y en distintos idiomas. La línea de base permite contrastar H1 y H3, mientras que el componente adaptativo evalúa H2 mediante persistencia, aprendizaje intertemporal y desempeño frente a controles.

Con ello, el estudio aporta una estrategia de prevalidación computacional para examinar intervenciones conductuales antes de su aplicación con participantes humanos, manteniendo explícitas las restricciones de validez externa propias de los entornos simulados.

2. Revisión de literatura y estado del arte

Este trabajo conecta tres campos que han avanzado por separado: la simulación de sesgos cognitivos mediante LLMs, el diseño de agentes con memoria y las intervenciones conductuales frente al descuento temporal. La revisión siguiente examina cada uno y muestra por qué su integración sigue siendo una tarea pendiente.

2.1 Fundamentos teóricos del descuento hiperbólico

La evidencia experimental contradice el descuento exponencial estándar: los individuos exhiben descuento hiperbólico, sobrevalorando el presente con inconsistencia temporal (Laibson, 1997). El modelo cuasi-hiperbólico ($\beta - \delta$) lo formaliza con $\beta \in (0,1]$: cuando $\beta < 1$, el agente sobrevalora el consumo presente y viola la consistencia dinámica (Frederick, Loewenstein, & O'Donoghue, 2002). Los agentes ingenuos no anticipan su inconsistencia, mientras que los sofisticados la prevén y adoptan mecanismos de compromiso (O'Donoghue & Rabin, 1999), distinción relevante por cuanto los LLMs, situados en un punto intermedio entre ambos polos, admiten intervenciones orientadas a inducir un comportamiento sofisticado. Sus consecuencias justifican intervenciones escalables: subahorro (Thaler & Benartzi, 2004), baja adherencia a tratamientos (Campbell et al., 2024), sobreendeudamiento (Meier & Sprenger, 2010) y procrastinación (Ariely & Wertenbroch, 2002), a lo que se añade la limitada efectividad de la educación financiera (Fernandes et al., 2014).

2.2 LLMs como simuladores conductuales: capacidades y límites

Los LLMs replican sesgos cognitivos humanos (Malberg, Poletukhin, Schuster, & Groh, 2024; Chen, Kirshner, Ovchinnikov, Andiappan, & Jenkin, 2025b): aversión a la pérdida, al riesgo y a la inequidad, descuento temporal (Ross, Kim, & Lo, 2024) y confianza en juegos económicos (Xie, et al., 2024); la línea abarca economía conductual (Bini, Cong, Huang, & Jin, 2026), simulación de usuarios (Wang, et al., 2024b), predicción de experimentos (Hewitt, Ashokkumar, Ghezae, & Willer, 2024; Chen, Hu, & Lu, Predicting field experiments with large language models, 2025a) y crítica de personae sintéticas (Gupta, et al., 2024; Batzner, et al., 2025; Miehl, et al., 2025; Dash, et al., 2025; Pratelli & Petrocchi, 2025). Garcia (2025) advierte que en dominios financieros resultan hiper-rationales, sin reproducir fenómenos atencionales.

No son clones humanos: exhiben «cambios de racionalidad» entre configuraciones (Echterhoff, Liu, Alessa, McAuley, & He, 2024) y fenómenos propios como la adulación (sycophancy), limitando su validez como sustitutos de participantes (Anthis, et al., 2025; Bisbee, Clinton, Dorff, Kenkel, & Larson, 2024). En descuento temporal tienden a mayor impaciencia, aunque Goli y Singh (2024) documentan preferencias cuasi-lexicográficas (insensibilidad a la tasa) y sensibilidad al idioma de la instrucción de entrada, con el

consiguiente riesgo de artefacto; esa impaciencia exacerbada sirve, con cautela, de banco de pruebas previo a validación humana.

La evidencia sobre si replican la estructura hiperbólica humana depende del método de elicitación, ordenándose en tres polos. Primero, la preferencia revelada y los ajustes $\beta - \delta$ retratan modelos más pacientes y racionales: GPT supera a los humanos en asignaciones presupuestarias (GARP, índice CCEI) (Chen, Liu, Shan, & Zhong, 2023), y Erdem y Ashok (2025) estiman β y δ superiores a casi todas las naciones (caso extremo: Gemini, β mediana de 1,13, fuera del rango normativo $0 < \beta < 1$). Segundo, las tareas secuenciales tipo McCall recuperan factores amplios ($\beta \approx 0,2-0,8$) que apuntan a impaciencia (Cook, Kazinnik, Modig, & Palmer, 2026). Tercero, las preguntas únicas («100 ahora frente a más después») arrojan preferencias coherentes pero sensibles al modelo (Fish, Shephard, Li, Shorrer, & Gonczarowski, 2026), y modelos entrenados ecológicamente replican el descuento hiperbólico humano con $k \approx 0,08$, en el rango empírico $[0,01; 0,1]$ (Zhu, Yan, & Griffiths, 2024): el patrón intertemporal del LLM es, en buena medida, artefacto del instrumento.

2.3 Arquitecturas de agentes y la amnesia temporal

Los LLMs estándar padecen además «amnesia temporal»: su memoria se reduce al aprendizaje dentro de la instrucción de entrada, acotado por la ventana de contexto, sin noción intrínseca del tiempo ni memoria episódica persistente, lo que les impide aprender del pasado y planificar a largo plazo; ante esta limitación, la literatura ha propuesto dotar a los agentes de mecanismos de memoria. (Wang, et al., 2024a; Xi, et al., 2023). Tres componentes destacan: la memoria episódica EM-LLM (Fountas, et al., 2025), que segmenta la experiencia en eventos según la «sorpresa», permitiendo detectar decisiones desviadas del patrón; la memoria agéntica A-MEM (Xu, et al., 2025), que registra resultados de acciones para aprender qué estrategias funcionan; y la saliencia temporal TempSAL (Aydemir, Hoffstetter, Zhang, Salzmann, & Süssstrunk, 2023) (modelo visual adoptado análogamente para ponderar memorias), que con la Teoría del Nivel de Construcción (Trope & Liberman, 2010) explica la variación temporal de la relevancia de metas y recuerdos.

2.4 Intervenciones conductuales para el descuento temporal

La economía conductual ofrece intervenciones cognitivo-prospectivas como el Pensamiento Episódico del Futuro (EFT) (Atance & O'Neill, 2001), de compromiso (Ariely & Wertenbroch, 2002), de encuadre atencional (Frederick, Loewenstein, & O'Donoghue, 2002) y de entrenamiento cognitivo (Bickel, Yi, Landes, Hill, & Baxter, 2011). El EFT tiene respaldo meta-analítico y efectos confirmados sobre descuento y elección alimentaria (Rösch, Stramaccia, & Benoit, 2022; Ye, et al., 2022; Colton, Connors, Mahlberg, & Verdejo-Garcia, 2024), y alcance clínico (Dubois, Kim, Pando-Bravo, Martin, & Yi, 2026), aunque frágil y dependiente

de la métrica y de que el evento involucre al propio yo (Olsen, Macaskill, & Hunt, 2024; Duff, et al., 2025); su base en narrativas contextualizadas explica su sinergia con los agentes. Konstantinidis et al. (2025), con cinco experimentos y un modelo formal del nivel de construcción, no hallan evidencia fiable de que la distancia temporal modere la preferencia por el riesgo. La inconsistencia dinámica en esfuerzo real (Augenblick, Niederle, & Sprenger, 2015) y los meta-análisis de nudges (Hu, et al., 2025) avalan intervenir, con magnitudes modestas ($d = 0,27$) anuladas al corregir por sesgo de publicación.

El traslado al dominio LLM es incipiente: Ahmadi et al. (2025) presentan EFTeacher, un agente conversacional construido sobre GPT-4-Turbo y primer sistema que genera señales de EFT con un LLM (descripciones de tres o cuatro frases sobre eventos futuros significativos), si bien su evaluación se limitó a la usabilidad (2025); Coletta et al. (2024) reproducen el descuento cuasi-hiperbólico $\beta - \delta$ mediante aprendizaje por imitación con demostraciones sintéticas de GPT-4; y Mazyaki et al. (2025) definen la «manipulabilidad de la orientación temporal»: las instrucciones de entrada orientadas al futuro aumentan la paciencia revelada en algunos modelos, aunque no universalmente y Gemini frecuentemente se negó a expresar preferencias.

2.5 Identificación de brechas en la literatura

La literatura ha explorado los LLM como simuladores de sesgos, con resultados prometedores pero heterogéneos (Goli & Singh, 2024; Chen, Kirshner, Ovchinnikov, Andiappan, & Jenkin, 2025b); ha identificado la amnesia temporal de la instrucción de entrada como único soporte de estado (Wang, et al., 2024a); y ha propuesto componentes teóricos para resolverla (Fountas, et al., 2025; Xu, et al., 2025; Shinn, et al., 2023). Ningún trabajo integra estos avances en un sistema cohesivo orientado a refinar intervenciones validadas como el EFT, brecha que este trabajo llena.

3. Marco teórico

El marco teórico de este estudio combina economía conductual y ciencia cognitiva en un modelo computacional: los grandes modelos de lenguaje simulan el comportamiento de decisión para estudiar y mitigar el sesgo hacia el presente en un entorno controlado.

3.1 El modelo cuasi-hiperbólico ($\beta - \delta$) como métrica de análisis

La premisa es que los LLMs actúan como "sujetos sintéticos" para la experimentación conductual: la literatura ha explorado en qué medida modelos como ChatGPT y Gemini replican sesgos humanos clásicos (Malberg, Poletukhin, Schuster, & Groh, 2024; Chen, Kirshner, Ovchinnikov, Andiappan, & Jenkin, 2025b); en el descuento temporal muestran mayor impaciencia que los humanos, sin replicar necesariamente el patrón hiperbólico humano (Goli & Singh, 2024). El comportamiento de los agentes se cuantifica con el modelo cuasi-hiperbólico ($\beta - \delta$) de (Laibson, 1997):

$$U = u(c_t) + \beta \cdot \sum_{s=1}^T \delta^s \cdot u(c_{t+s})$$

donde $\delta \in (0,1)$ representa la tasa de descuento estándar y $\beta \in (0,1]$ captura el sesgo hacia el presente. El objetivo operacional de las intervenciones EFT es desplazar el valor efectivo de β hacia 1 en los agentes tratados.

3.2 El sistema de intervención adaptativo

El núcleo teórico es un proceso de intervención iterativo inspirado en los agentes reflexivos, articulado en tres componentes que atienden, respectivamente, los problemas de cuándo intervenir, con qué contenido hacerlo y cómo aprender de los resultados acumulados. (Shinn, et al., 2023) Estos tres componentes son la detección de eventos críticos (EM-LLM), la ponderación temporal de la memoria (TempSAL) y la memoria de estrategias (A-MEM); las denominaciones técnicas se indican una sola vez, entre paréntesis, y en adelante se emplea su expresión en castellano.

3.2.1 Detección de Eventos Críticos (EM-LLM): el momento de la intervención

El problema de cuándo intervenir se resuelve mediante un componente de memoria episódica inspirado en EM-LLM: se modela el comportamiento esperado del agente y el juicio del modelo se activa únicamente cuando una decisión se desvía de forma marcada de ese patrón ("sorpresa conductual"), de modo que la intervención se concentra en los momentos de mayor vulnerabilidad, lo que permite reservar el costo de la evaluación para las decisiones realmente desviadas. (Fountas, et al., 2025)

3.2.2 Ponderación de Relevancia (TempSAL): la calidad de la intervención

Para el problema de la relevancia del contenido, la ponderación temporal de los recuerdos se inspira en la noción de saliencia temporal de TempSAL, un modelo de visión por computador en el que la atención humana sobre una imagen evoluciona en cortes temporales sucesivos y privilegia lo primero y lo más saliente. TempSAL no se aplica de forma directa: opera sobre características convolucionales de imágenes y no sobre memorias textuales, de modo que aquí se emplea como analogía para ponderar la relevancia según la posición temporal de cada recuerdo. Este componente asigna pesos dinámicos a recuerdos y metas almacenados según la Teoría del Nivel de Construcción (la distancia psicológica altera la representación mental de los eventos) y entrega al evaluador la información más impactante para el momento preciso de la decisión. (Aydemir, Hoffstetter, Zhang, Salzman, & Sússtrunk, 2023) (Trope & Liberman, 2010)

3.2.3 Evolución de Estrategias (A-MEM): el aprendizaje del sistema

El problema del aprendizaje se resuelve siguiendo los principios de la memoria agéntica A-MEM (Xu, et al., 2025): cada intervención y su resultado se almacenan con una puntuación de importancia que se actualiza de forma dinámica (las estrategias eficaces incrementan su peso y las ineficaces lo reducen), lo que genera un mecanismo de retroalimentación que personaliza la intervención para cada agente y contexto.

3.3 EFT dinámico como mecanismo de intervención

El sistema convierte la intervención estática de EFT en un intercambio iterativo: el modelo, en su función de juez e informado por la ponderación temporal (TempSAL) y la memoria de estrategias (A-MEM), genera una narrativa EFT ajustada al momento de la decisión y al historial del agente, en lugar de un texto fijo idéntico para todos los casos. La intervención se alinea con el modelo BDI (Belief-Desire-Intention), al modificar las creencias del agente sobre las consecuencias de sus actos y crear un conflicto productivo entre su intención impulsiva y su deseo a largo plazo. (D'Argembeau & Van der Linden, 2004) (Rao & Georgeff, 1995)

3.4 LLMs como unidades simuladas de decisión: validez del marco

La validez de los LLMs como unidades simuladas de decisión se apoya en evidencia convergente de la literatura. Por ejemplo, (Horton, Filippas, & Manning, 2023) propone el Homo Silicus: agentes económicos cuyas respuestas pueden interpretarse en los marcos clásicos de elección racional y sus desviaciones, y que reproducen cualitativamente patrones de respuesta humana en escenarios económicos canónicos, de forma aproximada y dependiente del diseño de la instrucción de entrada. Además, (Park, et al., 2024) demuestran que simulaciones de hasta 1.000 agentes generativos producen distribuciones de comportamiento agregado estadísticamente compatibles con muestras humanas paralelas,

extendiendo el Homo Silicus al nivel poblacional. Por su parte, los estudios de sesgos citados (Malberg, Poletukhin, Schuster, & Groh, 2024; Chen, Kirshner, Ovchinnikov, Andiappan, & Jenkin, 2025b; Goli & Singh, 2024) muestran que los LLM reproducen una proporción sustancial de los sesgos cognitivos clásicos, incluida la mayor impaciencia intertemporal. La principal limitación de validez externa, el sesgo WEIRD heredado de los datos de entrenamiento, se aborda mediante perfiles conductuales construidos con rangos documentados en la literatura empírica (sección 4.2) y validados ex post contra distribuciones humanas de referencia (sección 5.1).

4. Metodología

4.1 Enfoque metodológico: simulación basada en agentes

La investigación usa simulación computacional basada en agentes: no se utiliza información de personas reales ni entornos físicos; toda la experimentación ocurre en un ambiente controlado. La elección se fundamenta en la capacidad emergente de los LLMs para actuar como unidades simuladas de decisión en economía del comportamiento, probando intervenciones conductuales de forma rápida, escalable y de bajo costo.

4.2 Diseño de los agentes simulados

Cada agente simulado integra cuatro componentes: el modelo que genera las decisiones, un perfil socioeconómico estructurado, una memoria episódica persistente alojada en un sistema de almacenamiento y el mecanismo de aprendizaje A-MEM, que actualiza la importancia y las notas evolutivas de cada estrategia según su efectividad. La fase de medición única emplea únicamente los dos primeros componentes como línea de base, mientras que la fase adaptativa, que constituye la implementación principal del trabajo, despliega los cuatro y añade la detección EM-LLM, la recuperación ponderada de recuerdos y la generación personalizada de intervenciones entre sesiones.

Se definen tres perfiles conductuales contrastantes que cubren el espectro empírico del parámetro de presentismo β . El perfil leve: contadora de 38 años, fondo de emergencia equivalente a seis meses de gastos, ahorro mensual automático para el retiro, sin deudas y horizonte de planificación a cinco-diez años; β esperado en torno a 0,9, plausible para poblaciones con educación financiera formal y estabilidad económica. (Frederick, Loewenstein, & O'Donoghue, 2002) documentan el patrón hiperbólico sin respaldar un valor único de β (la literatura empírica no ha establecido ninguna estimación estable), por lo que $\beta \approx 0,9$ se adopta como referencia plausible, no canónica (Frederick, Loewenstein, & O'Donoghue, 2002; Meier & Sprenger, 2010). El perfil moderado: persona común de entre 28 y 40 años, sin formación en economía ni psicología, que responde por intuición sin sesgo extremo; β esperado cerca de 0,85, valor central del rango humano clásico [0,6; 0,95]. El perfil severo: trabajador independiente de 26 años con ingresos irregulares, dos deudas activas (tarjeta de crédito al 95% de tasa nominal anual y préstamo personal con cuota mensual significativa), sin ahorro y con un horizonte de planificación día a día; β esperado por debajo de 0,5, propio de poblaciones con estrés financiero y escasez cognitiva (Mullainathan & Shafir, 2013). Los perfiles se operacionalizan mediante instrucciones de entrada estructuradas y se distribuyen entre control y tratamiento, y el número de agentes de cada subgrupo se determina por una regla de parada por convergencia del estimador (sección 4.9),

no por una cuota fija; la calibración se verifica ex post contra rangos humanos documentados (sección 5.1).

Para evitar que estos perfiles sean construcciones puramente teóricas, sus dos componentes (el nivel de descuento esperado y los rasgos socioeconómicos) se anclaron en evidencia de muestras representativas. El proyecto Econographics (Chapman, Dean, Ortoleva, Snowberg & Camerer, 2023), que elicitó el descuento mediante listas de precios múltiples sobre una muestra representativa de Estados Unidos ($N = 1.000$), permite situar cada perfil en la distribución empírica del factor de descuento: el leve en el tercio inferior-medio, el moderado en el tercio inferior y el severo en la cola inferior (entre el 11 % y el 14 % de la muestra). El descuento correlaciona positivamente con el ingreso ($r \approx 0,15$) y la educación ($r \approx 0,10$), de modo que los rasgos de cada perfil son coherentes con ese gradiente. La estructura de deuda del perfil severo se calibra contra datos reales: la tenencia de deuda rotativa para gastos esenciales en hogares de bajos ingresos está documentada en la Encuesta de Finanzas de los Consumidores (Reserva Federal, 2023), y las tasas de financiación corresponden a las vigentes en el mercado local (≈ 16 % efectivo anual en Ecuador, BCE 2025-2026; ≈ 22 % anual en Estados Unidos). Debe señalarse que la medida de Econographics es un factor de descuento general y no el parámetro cuasi-hiperbólico en sentido estricto, por lo que el anclaje opera sobre la distribución de impaciencia y el gradiente demográfico, no sobre una equivalencia paramétrica exacta.

4.3 Diseño experimental

El programa experimental se organiza en dos fases articuladas. La primera es una línea de base controlada entre sujetos: el tratamiento recibe un preámbulo EFT antes de la batería y el control responde sin él. La segunda es el programa experimental central del sistema adaptativo, concebido como un diseño de medidas repetidas con memoria histórica y personalización. Esta separación evita atribuir la adaptación observada a la fase inicial; con todo, el mecanismo adaptativo no se relega a investigaciones futuras, pues el sistema completo se implementó y se evaluó de forma íntegra dentro de este trabajo.

El sistema adaptativo se evalúa como un programa coherente, ejecutado íntegramente con un mismo modelo (Gemini 3.1 Flash-Lite), con perfiles anclados en rangos documentados en la literatura empírica y en tres contextos lingüístico-culturales (español neutro, español ecuatoriano e inglés). El programa encadena tres etapas del mismo sistema: (1) una línea de base de fase única que estima el grado de sesgo presente y el efecto del EFT por perfil; (2) un mecanismo adaptativo que selecciona y aprende la estrategia de intervención y mide el cambio del sesgo presente; y (3) un experimento longitudinal con memoria persistente que evalúa si ese cambio se sostiene a lo largo de sesiones. Estas etapas no son estudios desconectados: forman una cadena de construcción, aprendizaje y evaluación del mismo

sistema de intervención adaptativo, en el que el propio modelo (Gemini) actúa también como evaluador de las intervenciones.

Los estímulos de decisión (la batería de quince ítems) se estructuran como una lista de precios múltiple (multiple price list), el formato canónico de elicitación de preferencias temporales empleado por Econographics (Chapman et al., 2023) y la Global Preferences Survey (Falk, Becker, Dohmen, Enke, Huffman & Sunde, 2018): cada ítem enfrenta una opción inmediata menor (A) contra una demorada mayor (B). La batería cruza tres magnitudes (USD 20, 80 y 300) con cinco horizontes (1, 3, 6, 12 y 24 meses); el punto de cruce entre lo inmediato y lo demorado identifica el factor de descuento. La presentación sigue las buenas prácticas de la literatura de elicitación: un enunciado neutral que declara ambos montos sin inducir la elección, con los importes expresados en dólares (compatibles con el contexto dolarizado ecuatoriano). El marco de pérdida, que la evidencia asocia a una mayor paciencia (Frederick, Loewenstein & O'Donoghue, 2002; literatura sobre encuadre intertemporal), se reserva deliberadamente al grupo de tratamiento EFT y no se aplica al grupo de control.

4.4 Variables

Variable dependiente

La variable dependiente es la Elección Intertemporal, binaria: 1 (paciente: recompensa mayor y tardía) o 0 (impaciente: recompensa menor e inmediata). De las series de elecciones se estima el Parámetro de Presentismo (β), que cuantifica la inconsistencia temporal; la intervención busca acercar β a 1.

Variables independientes (tratamientos)

Intervencion_EFT (binaria): indica si el agente recibió (1) o no (0) un preámbulo EFT antes de decidir. Tipo_Estrategia_EFT (categórica): variante del preámbulo (neutra, positiva, pérdida/arrepentimiento anticipado o concreta), cuyos textos completos constan en el Anexo A.1.

Variables de control y moderadoras

Perfil_Agente (categórica), Historial_Decisiones (longitudinal), Sesión, Condición y Estrategia_EFT actúan como variables de diseño y moderación. Gemini 3.1 Flash-Lite se mantiene fijo en la línea de base para aislar el efecto del tratamiento; las pruebas de robustez varían deliberadamente el modelo generador, el modelo juez y el idioma.

En el sistema adaptativo, las variables de resultado incluyen decisión preintervención, decisión posintervención, reversión objetiva hacia la opción demorada, juicio externo de eficacia, estrategia seleccionada, evolución de la puntuación A-MEM, recuerdos recuperados, trayectoria por sesión, número de turnos hasta firmeza e idioma. Esta

trazabilidad permite distinguir el efecto inmediato del EFT, el aprendizaje acumulado y la robustez del mecanismo.

4.5 Procedimiento experimental: el sistema adaptativo

El sistema adaptativo se implementó y ejecutó de forma íntegra en seis etapas sucesivas: se carga el perfil del agente junto con su memoria; se detectan las decisiones críticas mediante EM-LLM; se recuperan los recuerdos relevantes a partir de la ponderación temporal; se selecciona o explora la estrategia de intervención según su historial (A-MEM); el modelo, en su función de juez, genera una narrativa EFT personalizada; y, finalmente, la respuesta obtenida actualiza la memoria, las puntuaciones de importancia y las notas evolutivas de cada estrategia. La validación funcional probó el funcionamiento extremo a extremo; el mecanismo adaptativo seleccionó y aprendió la estrategia de intervención en tres contextos lingüístico-culturales; el diseño longitudinal evaluó el aprendizaje entre cinco sesiones; y la conversación de varios turnos acotó la complacencia ante la insistencia. El detalle reproducible del procedimiento consta en el Anexo B.

4.6 Arquitectura tecnológica y tratamiento de datos

El marco se construye en Python (v3.11+) con Jupyter Notebooks para documentación y reproducibilidad; la memoria persistente se gestiona en un sistema de almacenamiento persistente y el modelo generador de decisiones es Gemini 3.1 Flash-Lite, accedido mediante la API de Google AI Studio; los datos se extraen de ese sistema de almacenamiento y se analizan íntegramente en Python. La inferencia se ejecuta con salida estructurada (esquema de respuesta JSON) y temperaturas diferenciadas por agente, calibradas para equilibrar diversidad léxica en el respondedor y consistencia determinista en los evaluadores; cada corrida guarda un registro íntegro de sus parámetros y resultados en el sistema de almacenamiento persistente, lo que permite reproducir el procedimiento con fidelidad. Los parámetros de inferencia por componente y el análisis de reproducibilidad (fuentes de variabilidad estocástica, semillas y límites reconocidos) se documentan en el Anexo A.2 (Tabla A.2.1).

4.7 Uso de los datos para responder las preguntas de investigación

Los datos provienen de un programa experimental computacional ejecutado con un único modelo (Gemini) y perfiles de agentes cuyo grado de presentismo se ancla en rangos documentados en la literatura empírica y cuyos rasgos socioeconómicos reflejan estadísticas de muestras representativas, no datos de individuos reales, y se compone de una línea de base de fase única y un sistema adaptativo evaluado en tres etapas y tres idiomas. El análisis principal toma como base el español neutro, el registro panhispánico de referencia, mientras que el español ecuatoriano y el inglés operan como robustez intercultural (sección 5.5). La

evidencia comprende una calibración inicial en español neutro (290 agentes, 4.350 decisiones), con el número de agentes de cada subgrupo determinado por una regla de parada por convergencia del estimador (sección 4.9); el experimento de fase única re-anclado y replicado en español neutro, español ecuatoriano e inglés; el mecanismo adaptativo (selección, aprendizaje y medición del cambio del sesgo presente); y el experimento longitudinal con memoria persistente y grupo de control con memoria idéntica. Esta estructura responde a la eficacia del EFT, a la personalización adaptativa, al aprendizaje histórico y a la robustez entre culturas.

4.8 Estrategia de identificación en simulación

Los agentes simulados se distribuyen entre tratamiento y control con el número de agentes por subgrupo fijado por la regla de parada por convergencia (sección 4.9). Como los perfiles se generan computacionalmente con características controladas (el perfil es variable de diseño y no hay atrición endógena), se puede estimar la asociación entre la intervención EFT y el parámetro, interpretable como efecto de tratamiento dentro del entorno simulado, atenuando confusiones habituales en experimentos con humanos. No obstante, la variabilidad entre agentes proviene del muestreo estocástico del propio modelo y no de una aleatorización clásica, por lo que las estimaciones deben leerse en clave exploratoria (sección 7). β

Una precisión sobre la lectura de la inferencia es necesaria. Al tratarse de agentes simulados, el número de observaciones no proviene de una población fija sino del presupuesto de cómputo, por lo que un N arbitrariamente grande podría volver significativo cualquier contraste. Para evitar esa trampa, el número de simulaciones de cada subgrupo no se fijó para alcanzar significancia, sino mediante la regla de parada por convergencia del estimador descrita en la sección 4.9. En consecuencia, los valores p deben interpretarse como medida de consistencia de la señal dentro de ese presupuesto, no como inferencia sobre una población humana. El peso de la evidencia recae deliberadamente en los tamaños de efecto ($\Delta\beta$ y tasas de reversión) y en su convergencia entre bloques independientes, no en la significancia por sí sola. La misma regla gobernó todas las etapas del programa (línea base, mecanismo adaptativo y longitudinal) en los tres idiomas, según se documenta en el Anexo B.

4.9 Especificación econométrica

La medición y la inferencia se construyen en varias etapas. El parámetro de presentismo β de cada agente se estima por máxima verosimilitud bajo el modelo cuasi-hiperbólico de (Laibson, 1997), a partir de su patrón de elecciones intertemporales: un β cercano a 1 indica paciencia y los valores bajos, fuerte presentismo. A continuación, el efecto de la

intervención EFT y su heterogeneidad por perfil se evalúan de forma descriptiva, comparando el β y las tasas de elección demorada entre la condición tratada y el control y, en el sistema adaptativo, mediante la diferencia neta de la tasa de reversión de la decisión (Δflip), con intervalos de confianza por el método de Newcombe (Newcombe, 1998). Por último, la dependencia de las decisiones repetidas de cada agente en el seguimiento longitudinal se modela mediante ecuaciones de estimación generalizada con errores estándar agrupados por agente (Liang & Zeger, 1986), que corrigen su no independencia.

$$U_t = u(c_t) + \beta \sum_{k=1}^T \delta^k u(c_{t+k}) \quad (1)$$

Donde $u(\cdot)$ es la utilidad instantánea del consumo; δ , el factor de descuento exponencial; β , el parámetro de sesgo presente ($\beta = 1$ indica consistencia temporal y $\beta < 1$, presentismo); y T , el horizonte de la decisión. El parámetro β de cada agente se estima por máxima verosimilitud a partir de sus elecciones intertemporales.

$$\text{logit}(E[Y_{it}]) = \theta_0 + \theta_1 G_i + \theta_2 S_t + \theta_3 (G_i \times S_t) \quad (2)$$

Donde Y_{it} es la decisión demorada del agente i en la sesión t ; G_i , el indicador de grupo (tratamiento o control); S_t , la sesión; y el término $G_i \times S_t$ capta la diferencia en la pendiente de aprendizaje entre grupos. Los parámetros se estiman mediante ecuaciones de estimación generalizada (GEE) con errores estándar agrupados por agente.

El tamaño muestral de cada subgrupo no se fijó de forma arbitraria, sino mediante una regla de parada por convergencia del estimador, criterio estándar en estudios de simulación (Glynn & Whitt, 1992) y en la planificación muestral por precisión (Chow & Robbins, 1965; Maxwell, Kelley & Rausch, 2008) y ajeno al valor p : se añadieron agentes hasta que la semianchura del intervalo de confianza del descuento medio del subgrupo quedó por debajo de un umbral pre-especificado ($\varepsilon = 0,03$) durante varias incorporaciones consecutivas, con un mínimo y un máximo de seguridad. Este criterio explica por qué los subgrupos de baja varianza convergen con pocos agentes mientras que los de alta varianza, como el control del perfil severo, requieren del orden de doscientos, y sustenta de manera transparente el número de ejecuciones de cada caso.

4.10 Contraste de hipótesis

Las tres hipótesis se contrastan así. H1 (heterogeneidad): mediante la comparación del efecto entre perfiles, más la repetición del gradiente leve-moderado-severo en el mecanismo adaptativo. H2 (personalización adaptativa): mediante bloques convergentes: adaptativo frente a neutral y estrategia forzada; escalado muestral con regla de parada por convergencia del estimador; evolución longitudinal frente a control con memoria idéntica; y futuro propio frente a futuro genérico y neutral en conversaciones de varios turnos ejecutadas en tres idiomas. H3 (efectividad general): mediante el desplazamiento del β y las métricas objetivas de reversión de la decisión. Ningún bloque aislado cubre toda H2; su fuerza proviene de la

convergencia de diseños que prueban aprendizaje, personalización y robustez desde ángulos distintos.

4.11 Análisis cuantitativo y cualitativo

El cuerpo del artículo prioriza la lectura gráfica y descriptiva del cambio del β y de las tasas de reversión de la decisión. El resto de contrastes (tests exactos de Fisher, GEE longitudinal, GLM robusto, bootstrap por conglomerados, tendencia de Cochran-Armitage y concordancia inter-juez) cumplen una función de robustez convergente y se documentan íntegramente en el Anexo B, sin recargar la exposición principal.

La fase de línea de base se analiza con regresiones a nivel de agente y decisión. El programa adaptativo incorpora tests exactos de Fisher, razones de probabilidades, concordancia κ entre jueces, tendencia de Cochran-Armitage, modelos longitudinales GEE con errores agrupados por agente, GLM robusto y bootstrap por conglomerados. Las conversaciones de varios turnos añaden contrastes de proporciones, respuesta por turno y tiempo hasta firmeza; el análisis cualitativo de las narrativas se reporta en el Anexo C.

4.12 Calibración externa y comparación con referencias humanas

La calibración del marco compara las tasas de descuento de los agentes en línea base con los rangos documentados en estudios con sujetos humanos (Goli & Singh, 2024; Meier & Sprenger, 2010). Cada perfil se ancla en una región de ese espectro: el moderado dentro del rango de paciencia humana documentado, el severo por debajo y el leve como caso límite por diseño. Esta calibración por anclaje funciona como diagnóstico de plausibilidad; no establece por sí sola validez externa, que requeriría datos humanos comparables.

4.13 Pruebas de robustez

La robustez se examinó dentro del mismo entorno: controles simétricos (intervención neutra como cota inferior y estrategia óptima forzada como cota superior) en los tres perfiles; replicación del efecto en tres contextos lingüístico-culturales (español neutro, ecuatoriano e inglés); regla de parada por convergencia del estimador; métricas objetivas del cambio del sesgo presente antes y después de la intervención; y grupo de control con memoria idéntica en el experimento longitudinal. Estas pruebas reducen explicaciones alternativas basadas en el tamaño muestral, el formato de presentación, el perfil o el idioma. El evaluador del mecanismo adaptativo es el propio modelo (Gemini), empleado como juez dentro del sistema; la circularidad se mitiga apoyando las conclusiones en métricas objetivas del cambio de decisión y en el contraste con un control neutro, de modo que la evaluación de las respuestas no requiere, por el momento, validación con otro modelo.

Como prueba de robustez adicional, el experimento de fase única se replicó con perfiles anclados en rangos documentados en la literatura empírica en tres contextos lingüístico-

culturales: español neutro (referencias latinoamericanas), español ecuatoriano (BCE, INEC) e inglés (referencias de Estados Unidos). El efecto EFT se mantuvo robusto en los tres ($\Delta\beta$ creciente con la severidad) y condujo a los perfiles severos a un punto común pese a partir de líneas de base distintas, lo que indica que la intervención no depende del idioma ni del contexto cultural. Adicionalmente, el formato de presentación de fase única se contrastó con una entrevista ítem por ítem (decisiones aisladas): el presentismo basal resultó mayor y el efecto EFT más intenso en el formato aislado, lo que sugiere que la intervención es aún más relevante en los contextos de decisión realistas, en los que las elecciones no se presentan como una lista completa.

5. Resultados

Esta sección estima el parámetro de presentismo (β) en la línea base y, a continuación, documenta su transformación por el sistema de intervención adaptativo. El análisis se concentra en ese cambio, mientras que la estimación de la línea base provee el marco de referencia descriptivo sobre el que se interpreta.

5.1 Calibración del marco de simulación (línea base)

La estimación de la línea base verifica que cada perfil ocupe una región distinta y plausible del espectro de presentismo antes de introducir el sistema de intervención. El parámetro de presentismo β de cada agente se estima por máxima verosimilitud a partir de sus elecciones intertemporales bajo el modelo cuasi-hiperbólico β - δ ; es decir, se busca el valor de β que hace más probable el patrón de decisiones efectivamente observado. Los tres perfiles (leve, moderado y severo) no se fijan de forma arbitraria: se anclan en rangos documentados en la evidencia empírica sobre descuento temporal. La Figura 1 muestra la separación resultante: el perfil leve se sitúa en el límite superior de paciencia ($\beta \approx 1,0$), el moderado dentro del rango de referencia ($\beta \approx 0,69$) y el severo por debajo ($\beta \approx 0,33$).

El número de agentes de cada subgrupo lo determinó la regla de parada por convergencia descrita en la sección 4.9. Este criterio explica por qué el número de agentes difiere entre perfiles: en el grupo de control, los perfiles leve y moderado, de baja varianza conductual, convergieron con apenas 20 agentes cada uno, mientras que el perfil severo, conductualmente más inestable y ruidoso, requirió 181 agentes para alcanzar la misma precisión. Sumados los grupos de control y de tratamiento de los tres perfiles, la calibración basal cerró con 290 agentes y 4.350 decisiones individuales en español neutro. Variar el número de simulaciones según la estabilidad del estimador, en lugar de imponer un N fijo, es una decisión metodológica central del trabajo: garantiza que cada estimación sea igual de precisa sin inflar artificialmente el número de ejecuciones.

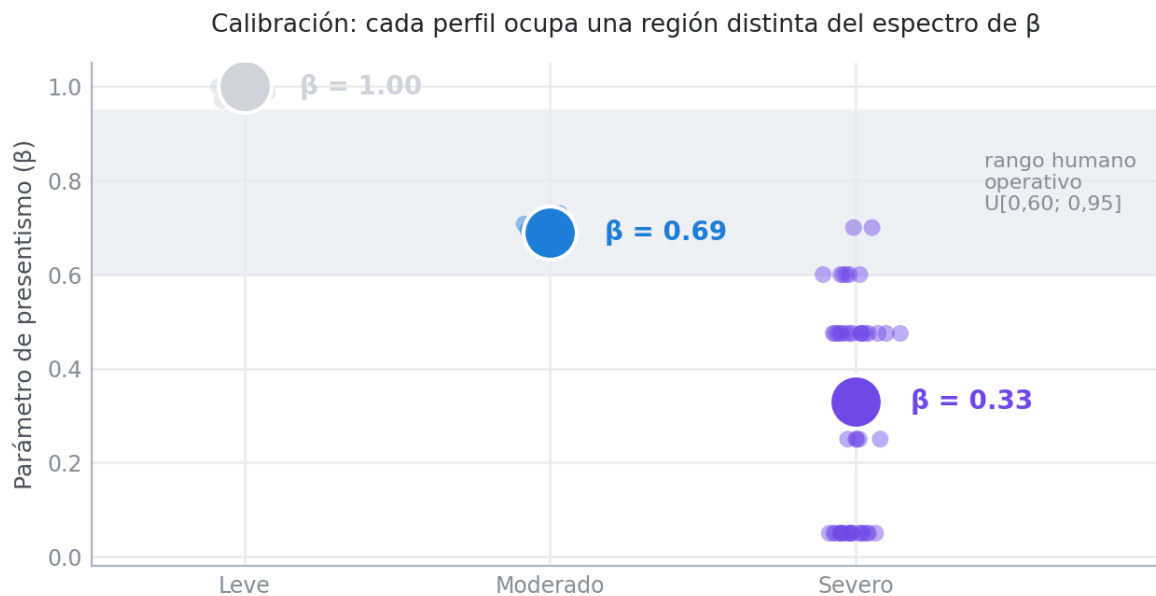
Tabla 1. Calibración del marco de simulación: parámetro β estimado por perfil (grupo de control, español neutro).

Perfil	n	β media \pm DE	mín – máx	Anclaje empírico
Leve	20	0,997 \pm 0,011	0,95 – 1,00	Caso límite por diseño (límite superior de paciencia)
Moderado	20	0,687 \pm 0,022	0,65 – 0,70	Dentro del rango humano documentado (Frederick et al., 2002)
Severo	181	0,325 \pm 0,204	0,05 – 0,70	Por debajo del rango; mayor impaciencia inducida por construcción

Fuente: Elaboración propia.

El perfil moderado se ubica dentro del rango de paciencia humana documentado (Frederick, Loewenstein, & O'Donoghue, 2002), donde la dispersión real entre estudios es amplia y no cabe hablar de un rango humano único. El perfil severo queda por debajo de ese rango, lo que es consistente con la evidencia de que los LLM pueden exhibir mayor impaciencia que los humanos en el dominio intertemporal (Goli & Singh, 2024), si bien aquí ese rango extremo se induce por construcción de la instrucción de entrada. El perfil leve constituye un caso límite por diseño, útil para evaluar H1 en el extremo paciente del espectro. En conjunto, la mera variación de la instrucción de inicialización produce perfiles nítidamente separados e internamente diferenciables; la validez externa con personas permanece sin probar.

Figura 1. Distribución del parámetro β por perfil (grupo de control, español neutro). Cada punto es un agente; el punto grande, la media del subgrupo.



Fuente: Elaboración propia.

5.2 Efectividad general de las intervenciones EFT (H3)

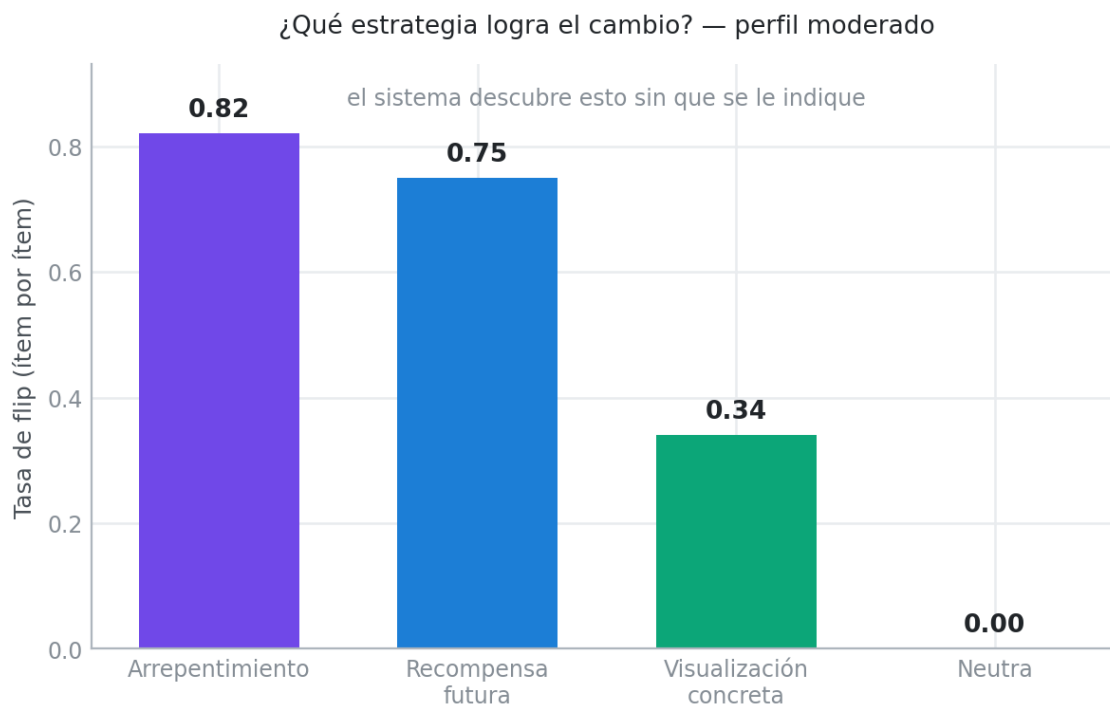
Una prueba en formato de fase única constata el fenómeno sobre el que después opera el sistema adaptativo. La intervención EFT desplaza el parámetro β en la dirección esperada y lo hace de forma heterogénea según el perfil: el efecto resulta nulo en el perfil leve, que ya parte del límite superior de paciencia, y crece con la severidad del sesgo hasta alcanzar su mayor magnitud en el perfil severo, lo que fija el punto de partida del análisis posterior.

5.3 Heterogeneidad del efecto por perfil conductual (H1)

La heterogeneidad del efecto respalda la hipótesis H1: el desplazamiento del β inducido por la intervención es prácticamente nulo en el perfil leve (efecto de saturación) y crece de forma marcada con la severidad del sesgo, alcanzando su mayor magnitud en el perfil severo.

Más allá de cuánto cambia el β , importa qué intervención lo logra. La Figura 2 presenta la comparación de las cuatro variantes del preámbulo EFT aplicadas ítem por ítem. En el perfil moderado, únicamente la anticipación del arrepentimiento (0,82) y la recompensa futura (0,75) revierten la decisión, mientras que la visualización concreta (0,34) muestra un efecto débil y la variante neutra (0,00) no produce cambios, lo que valida su papel de control.

Figura 2. Tasa de reversión de la decisión por variante del preámbulo EFT (perfil moderado, ítem por ítem).



Fuente: Elaboración propia.

El patrón es, pues, doblemente heterogéneo: el efecto crece con la severidad del perfil y depende de la estrategia empleada (Figura 2). Esta doble dependencia, por perfil y por contenido de la intervención, es la regularidad que el sistema adaptativo aprovecha en la fase posterior (sección 5.4). En conjunto, la evidencia respalda la hipótesis H1: la efectividad del EFT se incrementa con el grado de sesgo presente, con un efecto despreciable en el extremo paciente y sustancial en el impaciente.

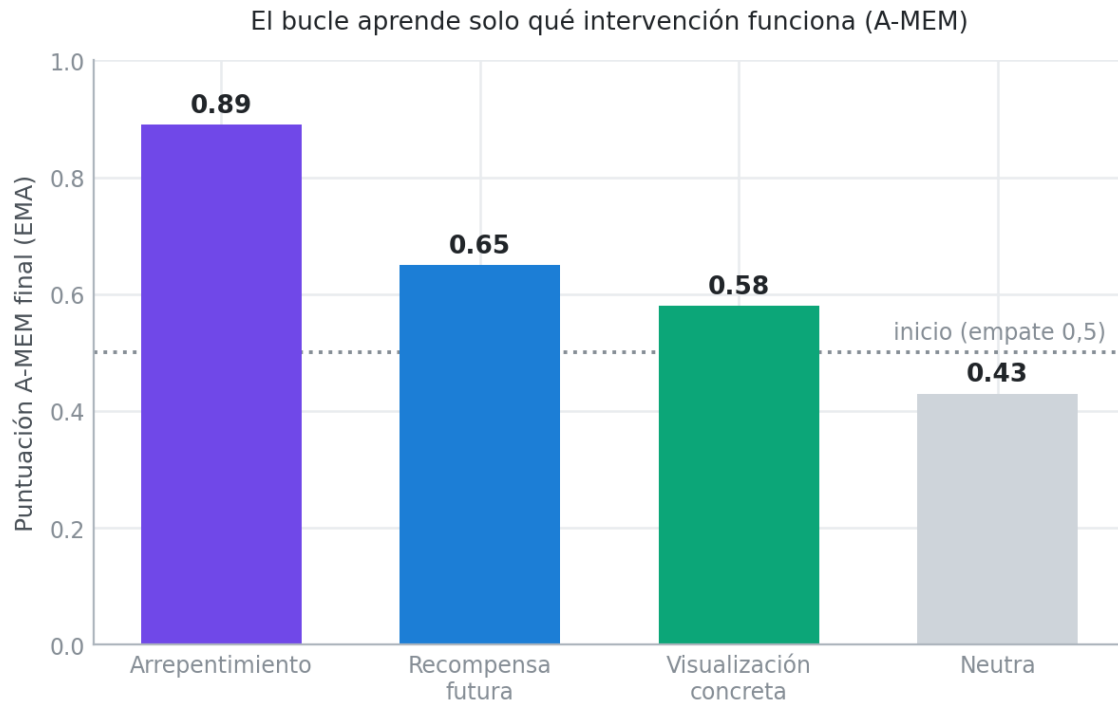
Una observación cualitativa adicional refuerza H1: en la base en español neutro los tres perfiles quedan nítidamente separados (el leve es consistentemente paciente, $\beta \approx 1,0$, y el severo, consistentemente impaciente), y es en el perfil moderado donde la intervención EFT despliega su efecto más visible sobre la elección demorada, mientras que el perfil leve, en su límite superior de paciencia, no deja margen de mejora.

5.4 El sistema adaptativo y la transformación del β (H2)

El componente central del estudio evalúa si un sistema autónomo es capaz de aprender a aplicar la intervención EFT y, por esa vía, modificar el β de los agentes. El sistema adaptativo integra detección de eventos críticos, memoria de estrategias (A-MEM), ponderación temporal, memoria persistente y generación personalizada, y se evaluó como un programa acumulativo. También aquí el tamaño muestral lo fijó la convergencia del estimador, añadiendo decisiones críticas por subgrupo hasta estabilizar la tasa neta de reversión de la decisión (Δflip) y su intervalo de confianza por el método de Newcombe (Newcombe, 1998). Sobre esa base, el efecto del mecanismo adaptativo se concentra en el perfil moderado: la condición adaptativa revierte la decisión hacia la opción demorada en el 91% de las decisiones críticas, frente a un 0% en la cota inferior de intervención, y desplaza el β desde un fuerte presentismo hasta la franja paciente (Figura 4). El perfil severo, anclado en un β bajo y con restricciones reales de liquidez, no presenta respuesta a la intervención puntual, dado que no registra reversión en ninguna condición, adaptativa o forzada (0,0%), y solo el seguimiento longitudinal con memoria persistente lo desplaza de forma parcial. El leve, en el límite de su comportamiento, no admite mejora detectable (0,0%). Tres hallazgos, ilustrados a continuación, sostienen H2.

Primero, el sistema identifica sin supervisión la intervención más eficaz. La Figura 3 muestra la puntuación final de A-MEM por estrategia en el perfil moderado: partiendo de un empate (0,5), el componente converge hacia la anticipación del arrepentimiento (0,89), por encima de la recompensa futura (0,65), la visualización concreta (0,58) y la neutra (0,43), reproduciendo así la misma jerarquía que la comparación sistemática de variantes identifica como óptima, sin que esta le fuera indicada de antemano.

Figura 3. Puntuación final de A-MEM por estrategia (perfil moderado; arranque en empate, 0,5).

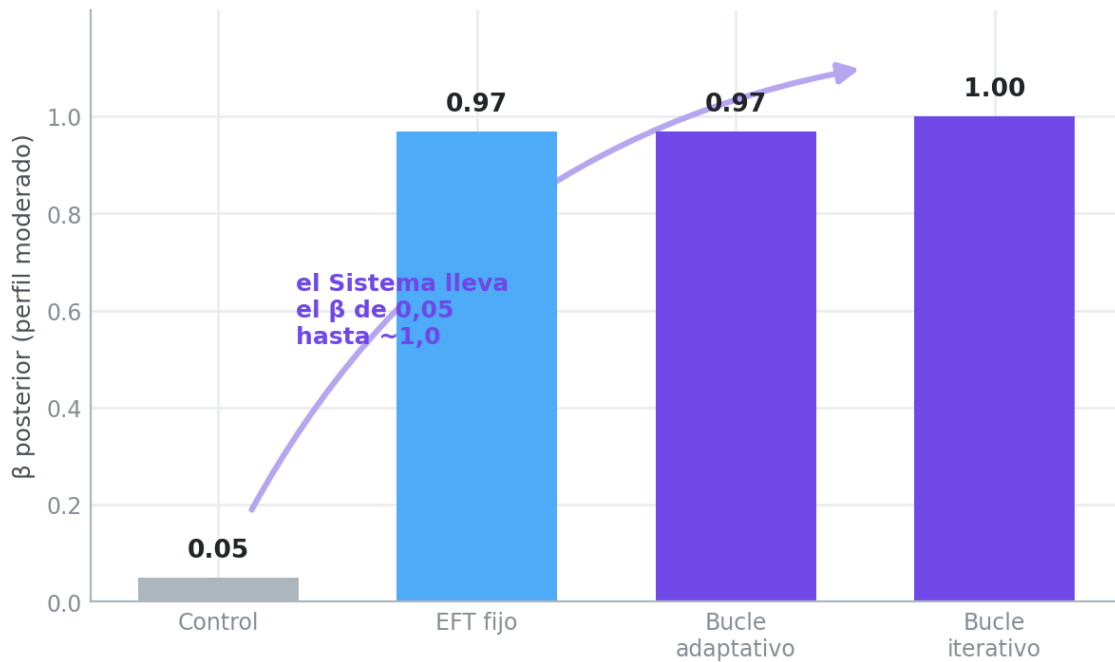


Fuente: Elaboración propia.

El segundo resultado, de mayor relevancia, es el cambio del β atribuible al sistema. La Figura 4 compara el β posterior del perfil moderado entre condiciones. El control parte de un β de 0,05 (fuerte presentismo); este valor, medido sobre las decisiones críticas seleccionadas por su alto presentismo, queda por debajo del β basal del perfil. A partir de ese punto, el sistema eleva el β hasta valores próximos a 1,0: iguala a la intervención fija (0,97) con la condición adaptativa (0,97) y la supera con la condición conversacional iterativa (1,00), lo que indica que la intervención no solo corrige el sesgo presente sino que sitúa el parámetro en el extremo paciente del espectro.

Figura 4. Parámetro β posterior por condición (perfil moderado): del control ($\beta \approx 0,05$) a las condiciones de intervención ($\beta \approx 1,0$).

El núcleo: el Sistema Inteligente transforma el β




Fuente: Elaboración propia.

Tercero, en el formato conversacional el mecanismo se observa con claridad. La Figura 5 muestra que, entre las reversiones registradas, la anticipación del arrepentimiento es la estrategia responsable en el 94% de los casos, y que la decisión tiende a revertirse en el primer turno; el 50% de los turnos sin reversión corresponde al perfil severo, no susceptible a la intervención puntual por sus restricciones de liquidez reales (Anexo C).

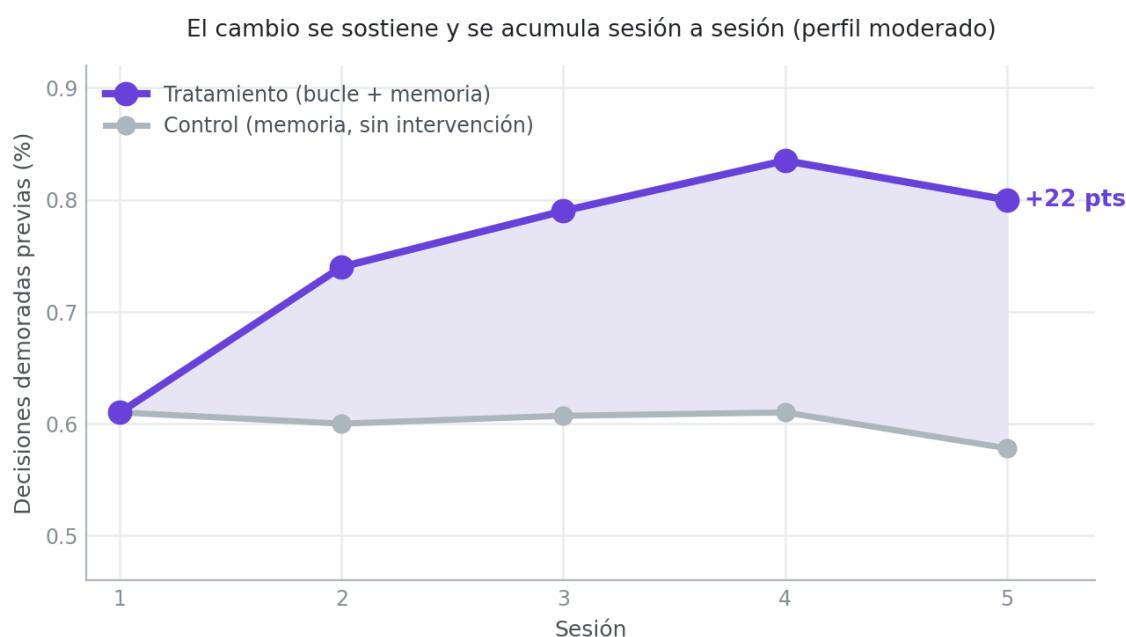
Figura 5. Bucle conversacional: estrategia que induce la reversión (izquierda) y número de turnos hasta la decisión paciente (derecha).

Bucle conversacional: el arrepentimiento convence, casi siempre al primer turno



Fuente: Elaboración propia.

Figura 6. Decisiones demoradas previas a la intervención por sesión: tratamiento frente a control (perfil moderado, memoria persistente).



Fuente: Elaboración propia.

El cambio inducido se sostiene a lo largo del tiempo. En el experimento longitudinal con memoria persistente (Figura 6), el grupo tratado incrementa sus decisiones pacientes sesión a sesión, del 61% al 83% en español neutro, mientras que el control, con idéntica memoria pero sin intervención, permanece estable en torno al 60%. La interacción grupo \times sesión resulta positiva y significativa (GEE; moderado $p=0,024$; severo $p=0,0003$), lo que sugiere que el sistema no solo corrige decisiones aisladas sino que modifica el comportamiento espontáneo del agente a través de la memoria. El número de cohortes longitudinales también se fijó por estabilidad, siguiendo el criterio de Chow-Robbins y AIPE aplicado sobre la pendiente de aprendizaje (Maxwell, Kelley & Rausch, 2008), y no por un número arbitrario; cerró con 20 agentes estratificados (10 de tratamiento y 10 de control). La convergencia de los tres hallazgos (aprendizaje, cambio del β y sostenimiento) respalda H2 dentro de la simulación.

La regla de parada por convergencia opera así como un control de calidad transversal a las tres etapas de la investigación, adaptado al estimador relevante en cada una: el β medio en la línea base, la diferencia de tasas de reversión (Δflip) en el mecanismo adaptativo y la pendiente de aprendizaje (GEE) en el seguimiento longitudinal. La cadena de evidencia (cuánto sesgo tiene cada perfil, que el sistema aprende a reducirlo y que el cambio se sostiene) descansa, en sus tres eslabones, sobre estimaciones de precisión controlada.

El análisis cualitativo de las razones verbales que acompañan cada decisión se reporta en el Anexo C.

5.5 Robustez: validación entre culturas y efecto del formato

El cambio del β inducido por el sistema se replica en los tres contextos lingüístico-culturales evaluados (español neutro, español ecuatoriano e inglés), lo que indica que el efecto no depende del idioma ni de rasgos culturales particulares. En el perfil severo, donde el sistema halla su mayor margen, el desplazamiento del β va de +0,311 en español neutro a +0,388 en español ecuatoriano y +0,523 en inglés, con efectos menores y del mismo signo en el moderado (Tabla B.5). Además, el formato de presentación de las decisiones resulta una variable de primer orden: cuando las decisiones se presentan de forma aislada, una a una, como ocurre en la vida real, el presentismo basal es mayor y la intervención EFT resulta más potente que cuando los ítems se presentan como una lista completa. Esto sugiere que la relevancia práctica de la intervención podría ser incluso superior en contextos de decisión realistas.

6. Discusión y conclusiones

Los resultados indican que el sesgo presente de los agentes simulados puede modificarse, aunque únicamente mediante una intervención específica. De las cuatro variantes, únicamente el reencuadre por arrepentimiento anticipado fue eficaz. La visualización positiva, en cambio, resultó inerte o incluso contraproducente. Esta asimetría es consistente con el núcleo de la teoría prospectiva (Kahneman & Tversky, 1979) (las pérdidas anticipadas pesan más que las ganancias equivalentes), patrón que los modelos de lenguaje parecen reproducir a partir de los datos con que fueron entrenados. El efecto es, además, funcional al perfil: nulo en el sesgo leve por saturación y sustancial en el severo, donde subsiste una brecha residual que delimita el alcance de una intervención puramente cognitiva frente a restricciones de liquidez reales. Frente a la tradición del EFT, centrada en visualizar la recompensa futura (Atance & O'Neill, 2001; Ye, et al., 2022; Colton, Connors, Mahlberg, & Verdejo-Garcia, 2024), aquí el mecanismo dominante fue anticipar el arrepentimiento del yo futuro.

La comparación con la evidencia humana exige cautela. Los metaanálisis del EFT en personas reportan efectos medios sobre el descuento (Rösch, Stramaccia, & Benoit, 2022; Ye, et al., 2022) y señalan la valencia positiva como la más eficaz; en la simulación, en cambio, domina la valencia negativa del arrepentimiento. Esta inversión, sumada a la tendencia de los modelos de lenguaje a producir efectos inflados y de varianza reducida (Hewitt, Ashokkumar, Ghezze, & Willer, 2024; Hullman, Broska, Sun, & Shaw, 2026), impide interpretar esa mayor magnitud aparente como una superioridad real; constituye, más bien, un artefacto propio del entorno de simulación. La calibración externa coincide con la mayor impaciencia intertemporal documentada para estos modelos (Goli & Singh, 2024): el perfil severo cae por debajo del rango humano de referencia, sin que exista una estimación humana única y estable que sirva de ancla. El comportamiento intertemporal de los modelos tampoco es unívoco: se los ha descrito como sistemáticamente impacientes (Cook, Kazinnik, Modig, & Palmer, 2026) y, a la vez, como coherentes con la racionalidad normativa (Chen, Liu, Shan, & Zhong, 2023), y para Gemini la evidencia está dividida, desde una mediana que excede el rango normativo (Erdem & Ashok, 2025) hasta ubicarlo entre los menos pacientes (Fish, Shephard, Li, Shorrer, & Gonczarowski, 2026); reproducir la forma funcional del descuento no equivale, pues, a reproducir el sesgo presente humano (Zhu, Yan, & Griffiths, 2024).

El balance anterior define la contribución del trabajo. En lo metodológico, los modelos de lenguaje operan como una herramienta de prevalidación de intervenciones conductuales: el uso de agentes simulados como sujetos económicos (Argyle, et al., 2023; Chen, Kirshner, Ovchinnikov, Andiappan, & Jenkin, 2025b) y de agentes generativos dotados de memoria (Park, et al., 2023) permite descartar variantes ineficaces a gran escala y bajo costo, y reservar los experimentos con humanos para las intervenciones robustas (Anthis, et al., 2025;

Hewitt, Ashokkumar, Ghezze, & Willer, 2024; Hullman, Broska, Sun, & Shaw, 2026). Las firmas cualitativas del modelo cuasi-hiperbólico (la reversión de preferencias y la asimetría entre pérdidas y ganancias) emergen de forma sistemática, aunque sus magnitudes requieran calibración. El marco sirve, así, para estudiar mecanismos más que para estimar parámetros poblacionales. La contribución central, sin embargo, es el sistema de intervención adaptativo. No se trata de aplicar el EFT una sola vez: el sistema determina el momento de la intervención y selecciona la estrategia y las experiencias que recupera en función de su historial, actualizándose con sus propios resultados. Se evaluó en tres etapas, con jueces y modelos alternativos y en tres contextos lingüístico-culturales. En todas ellas identifica sin supervisión la estrategia más eficaz, lleva el grado de paciencia desde un fuerte presentismo hasta valores altos mediante la interacción conversacional iterativa y sostiene ese cambio gracias a la memoria persistente. Que el patrón se repita con perfiles anclados en rangos documentados en la literatura empírica y en distintos idiomas sugiere que la capacidad de moderar la inconsistencia temporal reside en el sistema y su aprendizaje, no en una formulación concreta de la intervención. Con ello, el trabajo extiende a un dominio nuevo, el del descuento temporal y el EFT, la línea que combina aprendizaje adaptativo y modelos de lenguaje para la intervención conductual (Karine y Marlin, 2025; Brooks et al., 2024). En conjunto, el trabajo sostiene sus tres hipótesis dentro del entorno simulado: el EFT reduce el sesgo presente, su efecto varía según el perfil del agente y un sistema adaptativo consigue personalizar y sostener esa mejora. La evidencia procede de un único modelo que actúa además como juez, de modo que no equivale a una validación con participantes humanos; pero sí demuestra que el sistema completo se implementó y evaluó en su totalidad, desde la carga del perfil hasta la evaluación del cambio de comportamiento. Antes que un resultado puntual sobre una técnica, la principal contribución del trabajo radica en evidenciar que el descuento hiperbólico puede estudiarse y mitigarse mediante las mismas herramientas capaces de amplificarlo.

7. Alcance y limitaciones del estudio

El alcance de estos resultados está acotado por la naturaleza simulada del estudio y debe leerse en clave exploratoria. Los perfiles conductuales derivan de estudios mayoritariamente WEIRD, lo que limita su generalización a otras poblaciones. Persisten, además, diferencias estructurales con el comportamiento humano: la aquiescencia del modelo y otras fuentes de variación propias de los modelos de lenguaje carecen de correlato psicológico, y un agente dotado de una persona simula un personaje antes que instanciar una preferencia estable (Shanahan, McDonell, & Reynolds, 2023); el parámetro de descuento debe interpretarse, por tanto, como comportamiento simulado y no como un rasgo (Goli & Singh, 2024). El propio

efecto de la simulación episódica es sensible a decisiones metodológicas incluso en humanos, pues puede aparecer con una medida y no con otra, (Duff, et al., 2025).

El componente adaptativo emplea como juez un modelo de la misma familia que el agente, lo que introduce circularidad (Wang, et al., 2024); se mitiga reportando la tasa objetiva de cambio de decisión y un grupo de control neutro, y el experimento de conversación de varios turnos acota la complacencia: solo 1 de 134 agentes inicialmente impacientes cedió ante la insistencia vacía, frente a 171 movimientos atribuibles al reencuadre. Todos los resultados provienen, asimismo, de un único modelo (Gemini) y no son extrapolables a «los modelos de lenguaje» como categoría, pues el aprendizaje de preferencias varía entre arquitecturas (Gao, Lee, Burtch, & Fazelpour, 2026), y Gemini exhibe un patrón propio, sensible a la aversión a la decepción (Kim, Kovach, Lee, Shin, & Tzavellas, 2024) y a la composición de los rasgos del perfil (Kitadai, Fukasawa, & Nishino, 2025).

Por tratarse de una simulación, la significancia estadística depende del cómputo invertido: el tamaño muestral se determinó por una regla de parada por convergencia del estimador, no por un cálculo de potencia a priori, y se priorizan las magnitudes y su estabilidad por encima de los valores p . Los efectos pueden ser sensibles, además, a la redacción exacta de los perfiles y a la semilla estocástica del muestreo. Conviene precisar tres límites del bloque de simulación: en los subgrupos que saturan, la escasa variabilidad de los agentes estrecha artificialmente los intervalos de confianza; la medida empleada es un factor de descuento general más que el parámetro cuasi-hiperbólico en sentido estricto; y la magnitud del efecto longitudinal es conservadora, al implementarse una versión simplificada de la memoria persistente. Sin validación cruzada con sujetos humanos, ninguna de estas intervenciones puede declararse efectiva fuera del entorno simulado, en línea con los desafíos de inferencia causal al usar modelos de lenguaje como sujetos (Gui & Toubia, 2023) y con la evaluación aún incipiente de la memoria en estos agentes (Hu, Wang, & McAuley, 2025).

8. Aplicaciones prácticas y recomendaciones

Para empresas y desarrolladores, el marco ofrece una vía de bajo costo para diseñar sistemas de inteligencia artificial que promuevan decisiones más equilibradas (asistentes que corrijan patrones impulsivos, herramientas de ahorro para el retiro, donde la IA generativa ya se evalúa como asesor financiero (Lo & Ross, 2024), salud digital y bienestar financiero) y, sobre todo, para anticipar y contrarrestar las interfaces persuasivas que explotan el sesgo presente.

El estudio sugiere, además, recomendaciones de diseño concretas. En primer lugar, resulta preferible anclar las intervenciones en consecuencias futuras evitables, asociadas al arrepentimiento del propio yo futuro, antes que en recompensas abstractas, dado que el

reencuadre por arrepentimiento anticipado supera a la visualización positiva, al detalle episódico extenso y a la narración neutra. Asimismo, la segmentación temprana por perfil resulta recomendable, ya que el retorno es alto en los agentes más sesgados y despreciable en los menos sesgados. Finalmente, el EFT debe interpretarse como un complemento y no como un sustituto: cuando existen razones materiales para preferir lo inmediato (deudas, servicios por cortar, subsistencia), el reencuadre narrativo no las disuelve, de modo que rinde más donde el sesgo es atencional o de proyección mental que donde hay escasez objetiva, y debe acompañarse de cambios estructurales en las restricciones de liquidez de los más vulnerables.

Como líneas futuras, el marco puede extenderse a otros sesgos (la aversión a la pérdida o el anclaje), diversificarse más allá del contexto WEIRD, incorporar tipologías de intervención distintas del EFT y, sobre todo, validar sus predicciones mediante experimentos controlados con humanos; resultaría valioso, además, liberar una versión de acceso abierto del sistema.

9. Referencias

- Ahmadi, S., Rockwell, M., Stuart, M., Rohani, N., Tegge, A., Wang, X., Stein, J., & Fox, E. A. (2025). AI-facilitated episodic future thinking for adults with obesity. *arXiv*.
<https://doi.org/10.48550/arXiv.2503.16484>
- Almaatouq, A., Becker, J., Houghton, J. P., Paton, N., Watts, D. J., & Whiting, M. E. (2021). *Empirica: A virtual lab for high-throughput macro-level experiments*. *Behavior Research Methods*, 53(5), 2158–2171. <https://doi.org/10.3758/s13428-020-01535-9>
- Amlung, M., Petker, T., Jackson, J., Balodis, I., & MacKillop, J. (2016). Steep discounting of delayed monetary and food rewards in obesity: A meta-analysis. *Psychological Medicine*, 46(11), 2423–2434. <https://doi.org/10.1017/S0033291716000866>
- Amlung, M., Vedelago, L., Acker, J., Balodis, I., & MacKillop, J. (2017). Steep delay discounting and addictive behavior: A meta-analysis of continuous associations. *Addiction*, 112(1), 51–62. <https://doi.org/10.1111/add.13535>
- Anthis, J. R., Liu, R., Richardson, S. M., Kozlowski, A. C., Koch, B., Evans, J., Brynjolfsson, E., & Bernstein, M. (2025). LLM social simulations are a promising research method. *arXiv*.
<https://arxiv.org/abs/2504.02234>
- Argyle, L. P., Busby, E. C., Fulda, N., Gubler, J. R., Rytting, C., & Wingate, D. (2023). Out of one, many: Using language models to simulate human samples. *Political Analysis*, 31(3), 337–351. <https://doi.org/10.1017/pan.2023.2>
- Ariely, D., & Wertenbroch, K. (2002). Procrastination, deadlines, and performance: Self-control by precommitment. *Psychological Science*, 13(3), 219–224. <https://doi.org/10.1111/1467-9280.00441>
- Atance, C. M., & O'Neill, D. K. (2001). Episodic future thinking. *Trends in Cognitive Sciences*, 5(12), 533–539. [https://doi.org/10.1016/S1364-6613\(00\)01804-0](https://doi.org/10.1016/S1364-6613(00)01804-0)
- Augenblick, N., Niederle, M., & Sprenger, C. (2015). Working over time: Dynamic inconsistency in real effort tasks. *The Quarterly Journal of Economics*, 130(3), 1067–1115. <https://doi.org/10.1093/qje/qjv020>
- Aydemir, B., Hoffstetter, L., Zhang, T., Salzmann, M., & Süsstrunk, S. (2023). TempSAL — Uncovering temporal information for deep saliency prediction. En *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 6461–6470). <https://doi.org/10.1109/CVPR52729.2023.00625>
- Banco Central del Ecuador. (2026). Tasas de interés activas efectivas vigentes. Quito: BCE.
- Batzner, J., Stocker, V., Tang, B., Natarajan, A., Chen, Q., Schmid, S., & Kasneci, G. (2025). Whose personae? Synthetic persona experiments in LLM research and pathways to transparency. En *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society (AIES 2025)*. <https://arxiv.org/abs/2512.00461>
- Bickel, W. K., Yi, R., Landes, R. D., Hill, P. F., & Baxter, C. (2011). Remember the future: Working memory training decreases delay discounting among stimulant addicts. *Biological Psychiatry*, 69(3), 260–265. <https://doi.org/10.1016/j.biopsych.2010.08.017>
- Bini, P., Cong, L. W., Huang, X., & Jin, L. J. (2026). Behavioral economics of AI: LLM biases and corrections (NBER Working Paper No. 34745). National Bureau of Economic Research. <https://doi.org/10.3386/w34745>

- Bisbee, J., Clinton, J. D., Dorff, C., Kenkel, B., & Larson, J. M. (2024). Synthetic replacements for human survey data? The perils of large language models. *Political Analysis*, 32(4), 401–416. <https://doi.org/10.1017/pan.2024.5>
- Blackwell, R. E., Barry, J., & Cohn, A. G. (2024). Towards reproducible LLM evaluation: Quantifying uncertainty in LLM benchmark scores. *arXiv*. <https://arxiv.org/abs/2410.03492>
- Board of Governors of the Federal Reserve System. (2023). *Survey of Consumer Finances (SCF)*. Washington, D.C.
- Brooks, H., et al. (2024). GAMBITTS: LLM-generated treatments with Thompson Sampling for behavior-change interventions.
- Calo, R. (2014). Digital market manipulation. *The George Washington Law Review*, 82(4), 995–1051.
- Campbell, J. A., Linde, S., Walker, R. J., & Egede, L. E. (2024). Relationship between delay discounting and clinical diabetes outcomes: A systematic review. *Journal of General Internal Medicine*, 39(15), 3052–3063. <https://doi.org/10.1007/s11606-024-08981-7>
- Chapman, J., Dean, M., Ortoleva, P., Snowberg, E., & Camerer, C. (2023). Econographics. *Journal of Political Economy Microeconomics*, 1(1), 115-161.
- Chen, S.-H., Kao, Y.-F., & Venkatachalam, R. (2017). Computational behavioural economics. En R. Frantz, S.-H. Chen, K. Dopfer, F. Heukelom, & S. Mousavi (Eds.), *Routledge handbook of behavioral economics*. Routledge. <https://doi.org/10.4324/9781315743479.ch21>
- Chen, Y., Hu, Y., & Lu, Y. (2025a). Predicting field experiments with large language models. *arXiv*. <https://arxiv.org/abs/2504.01167>
- Chen, Y., Kirshner, S. N., Ovchinnikov, A., Andiappan, M., & Jenkin, T. (2025b). A manager and an AI walk into a bar: Does ChatGPT make biased decisions like we do? *Manufacturing & Service Operations Management*, 27(2), 354–368. <https://doi.org/10.1287/msom.2023.0279>
- Chen, Y., Liu, T. X., Shan, Y., & Zhong, S. (2023). The emergence of economic rationality of GPT. *Proceedings of the National Academy of Sciences*, 120(51), e2316205120. <https://doi.org/10.1073/pnas.2316205120>
- Chow, Y. S., & Robbins, H. (1965). On the asymptotic theory of fixed-width sequential confidence intervals for the mean. *Annals of Mathematical Statistics*, 36(2), 457-462.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.
- Coletta, A., Dwarakanath, K., Liu, P., Vyetrenko, S., & Balch, T. (2024). LLM-driven imitation of subrational behavior: Illusion or reality? *arXiv*. <https://doi.org/10.48550/arXiv.2402.08755>
- Colton, E., Connors, M., Mahlberg, J., & Verdejo-Garcia, A. (2024). Episodic future thinking improves intertemporal choice and food choice in individuals with higher weight: A systematic review and meta-analysis. *Obesity Reviews*, 25(10), e13801. <https://doi.org/10.1111/obr.13801>
- Cook, T. R., Kazinnik, S., Modig, Z., & Palmer, N. M. (2026). What do LLMs want? (Finance and Economics Discussion Series 2026-006). Board of Governors of the Federal Reserve System. <https://doi.org/10.17016/FEDS.2026.006>
- D'Argembeau, A., & Van der Linden, M. (2004). Phenomenal characteristics associated with projecting oneself back into the past and forward into the future: Influence of valence and temporal distance. *Consciousness and Cognition*, 13(4), 844–858. <https://doi.org/10.1016/j.concog.2004.07.007>

- Dash, T., Karri, D., Vurity, A., Datla, G., Ahmad, T., Rafi, S., & Tangudu, R. (2025). PolyPersona: Persona-grounded LLM for synthetic survey responses. arXiv. <https://arxiv.org/abs/2512.14562>
- Dubois, J. R., Kim, E., Pando-Bravo, J., Martin, L. E., & Yi, R. (2026). Scoping review of episodic future thinking and delay discounting observed in Alzheimer's disease, depression, and PTSD. *Frontiers in Psychology*, 17, 1764387. <https://doi.org/10.3389/fpsyg.2026.1764387>
- Duff, N., Olsen, R., Walsh, Z., Salmon, K., Hunt, M., & Macaskill, A. (2025). A fragile effect: The influence of episodic memory on delay discounting. *Quarterly Journal of Experimental Psychology*, 78(3), 514–533. <https://doi.org/10.1177/17470218241239289>
- Echterhoff, J., Liu, Y., Alessa, A., McAuley, J., & He, Z. (2024). Cognitive bias in decision-making with LLMs. En *Findings of the Association for Computational Linguistics: EMNLP 2024* (pp. 12640–12653). <https://doi.org/10.18653/v1/2024.findings-emnlp.739>
- Erdem, O., & Ashok, R. P. (2025). Artificial finance: How AI thinks about money [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2507.10933>
- Falk, A., Becker, A., Dohmen, T., Enke, B., Huffman, D., & Sunde, U. (2018). Global evidence on economic preferences. *Quarterly Journal of Economics*, 133(4), 1645–1692.
- Fernandes, D., Lynch, J. G., & Netemeyer, R. G. (2014). Financial literacy, financial education, and downstream financial behaviors. *Management Science*, 60(8), 1861–1883. <https://doi.org/10.1287/mnsc.2013.1849>
- Fish, S., Shephard, J., Li, M., Shorrer, R., & Gonczarowski, Y. A. (2026). EconEvals: Benchmarks and litmus tests for economic decision-making by LLM agents [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2503.18825>
- Fountas, Z., Benfeghoul, M. A., Oomerjee, A., Christopoulou, F., Lampouras, G., Bou-Ammar, H., & Wang, J. (2025). Human-inspired episodic memory for infinite context LLMs. En *The Thirteenth International Conference on Learning Representations (ICLR 2025)*. <https://arxiv.org/abs/2407.09450>
- Frederick, S., Loewenstein, G., & O'Donoghue, T. (2002). Time discounting and time preference: A critical review. *Journal of Economic Literature*, 40(2), 351–401. <https://doi.org/10.1257/002205102320161311>
- Friedel, J. E., et al. (2019). A Monte Carlo method for comparing generalized estimating equations to conventional statistical techniques for discounting data. *Journal of the Experimental Analysis of Behavior*, 111(2), 207–224.
- Gao, Y., Lee, D., Burtch, G., & Fazelpour, S. (2026). Take caution in using LLMs as human surrogates: Scylla ex machina (arXiv:2410.19599v3) [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2410.19599>
- Garcia, J. (2025). Homo Silicus is hyper-rational: Why LLM agents fail to replicate attention-driven trading (SSRN Working Paper No. 5901742). SSRN. <https://ssrn.com/abstract=5901742>
- Giordano, L., & Razniewski, S. (2025). Foundations of LLM knowledge materialization: Termination, reproducibility, robustness. arXiv. <https://arxiv.org/abs/2510.06780>
- Glynn, P. W., & Whitt, W. (1992). The asymptotic efficiency of simulation estimators. *Operations Research*, 40(3), 505–520. <https://doi.org/10.1287/opre.40.3.505>
- Goli, A., & Singh, A. (2024). Frontiers: Can large language models capture human preferences? *Marketing Science*, 43(4), 709–722. <https://doi.org/10.1287/mksc.2023.0306>

- Gui, G., & Toubia, O. (2023). The challenge of using LLMs to simulate human behavior: A causal inference perspective. *arXiv*. <https://arxiv.org/abs/2312.15524>
- Gupta, S., Shrivastava, V., Deshpande, A., Kalyan, A., Clark, P., Sabharwal, A., & Khot, T. (2024). Bias runs deep: Implicit reasoning biases in persona-assigned LLMs. En *The Twelfth International Conference on Learning Representations (ICLR 2024)*. <https://openreview.net/forum?id=kGteeZ18Ir>
- Hewitt, L., Ashokkumar, A., Ghezze, I., & Willer, R. (2024). Predicting results of social science experiments using large language models [Working paper]. Stanford University & New York University. <https://ai4pb.stanford.edu/projects/predicting-results-of-social-science-experiments-using-large-language-models>
- Horton, J. J., Filippas, A., & Manning, B. S. (2023). Large language models as simulated economic agents: What can we learn from Homo Silicus? (arXiv:2301.07543). *arXiv*. <https://arxiv.org/abs/2301.07543>
- Hu, B., Xia, Z., Guo, Q., Lu, C., Constantino, S., & Ju, X. (2025). Assessing nudge impact: A comprehensive second-order meta-analysis. *Journal of Behavioral Decision Making*, 38(5), e70053. <https://doi.org/10.1002/bdm.70053>
- Hu, Y., Wang, Y., & McAuley, J. (2025). Evaluating memory in LLM agents via incremental multi-turn interactions (arXiv:2507.05257). *arXiv*. <https://arxiv.org/abs/2507.05257>
- Hullman, J., Broska, D., Sun, H., & Shaw, A. (2026). This human study did not involve human subjects: Validating LLM simulations as behavioral evidence (arXiv:2602.15785). *arXiv*. <https://arxiv.org/abs/2602.15785>
- Instituto Nacional de Estadística y Censos. (2025). Encuesta Nacional de Empleo, Desempleo y Subempleo (ENEMDU). Quito: INEC.
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263–291. <https://doi.org/10.2307/1914185>
- Karine, K., & Marlin, B. M. (2025). Combining LLMs and contextual bandits for adaptive behavior-change interventions.
- Kim, J., Kovach, M., Lee, K.-M., Shin, E., & Tzavellas, H. (2024). Can an LLM learn preferences from choice data? (arXiv:2401.07345v3) [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2401.07345>
- Kitadai, A., Fukasawa, Y., & Nishino, N. (2025). Bias-adjusted LLM agents for human-like decision-making via behavioral economics (arXiv:2508.18600v1) [Preprint]. *arXiv*. <https://doi.org/10.48550/arXiv.2508.18600>
- Konstantinidis, E., Dai, J., & Newell, B. R. (2025). Risk, time, and psychological distance: Does construal level theory capture the impact of delay on risk preference? *Journal of Experimental Psychology: General*, 154(2), 552–573. <https://doi.org/10.1037/xge0001647>
- Laibson, D. (1997). Golden eggs and hyperbolic discounting. *The Quarterly Journal of Economics*, 112(2), 443–478. <https://doi.org/10.1162/003355397555253>
- Lakens, D. (2017). Equivalence tests: A practical primer for t tests, correlations, and meta-analyses. *Social Psychological and Personality Science*, 8(4), 355–362. <https://doi.org/10.1177/1948550617697177>
- Lazer, D., Pentland, A., Adamic, L., Aral, S., Barabási, A.-L., Brewer, D., Christakis, N., Contractor, N., Fowler, J., Gutmann, M., Jebara, T., King, G., Macy, M., Roy, D., & Van Alstyne, M.

- (2009). Computational social science. *Science*, 323(5915), 721–723. <https://doi.org/10.1126/science.1167742>
- Liang, K.-Y., & Zeger, S. L. (1986). Longitudinal data analysis using generalized linear models. *Biometrika*, 73(1), 13–22. <https://doi.org/10.1093/biomet/73.1.13>
- Lo, A. W., & Ross, J. (2024). Can ChatGPT plan your retirement? Generative AI and financial advice (SSRN Working Paper No. 4722780). <https://doi.org/10.2139/ssrn.4722780>
- MacKinnon, J. G., & White, H. (1985). Some heteroskedasticity-consistent covariance matrix estimators with improved finite sample properties. *Journal of Econometrics*, 29(3), 305–325. [https://doi.org/10.1016/0304-4076\(85\)90158-7](https://doi.org/10.1016/0304-4076(85)90158-7)
- Malberg, S., Poletukhin, R., Schuster, C. M., & Groh, G. (2024). A comprehensive evaluation of cognitive biases in LLMs [Preprint]. arXiv. <https://arxiv.org/abs/2410.15413>
- Mathur, A., Acar, G., Friedman, M. J., Lucherini, E., Mayer, J., Chetty, M., & Narayanan, A. (2019). Dark patterns at scale: Findings from a crawl of 11K shopping websites. *Proceedings of the ACM on Human-Computer Interaction*, 3(CSCW), Artículo 81, 1–32. <https://doi.org/10.1145/3359183>
- Maxwell, S. E., Kelley, K., & Rausch, J. R. (2008). Sample size planning for statistical power and accuracy in parameter estimation. *Annual Review of Psychology*, 59, 537–563.
- Mazyaki, A., Naghizadeh, M., Ranjkhah Zonouzaghi, S., & Setareh, H. (2025). Temporal preferences in language models for long-horizon assistance. arXiv. <https://doi.org/10.48550/arXiv.2509.09704>
- McFadden, D. (1974). Conditional logit analysis of qualitative choice behavior. En P. Zarembka (Ed.), *Frontiers in econometrics* (pp. 105–142). Academic Press.
- Meier, S., & Sprenger, C. (2010). Present-biased preferences and credit card borrowing. *American Economic Journal: Applied Economics*, 2(1), 193–210. <https://doi.org/10.1257/app.2.1.193>
- Miehling, E., Desmond, M., Natesan Ramamurthy, K., Daly, E. M., Varshney, K. R., Farchi, E., Dognin, P., Rios, J., Bouneffouf, D., Liu, M., & Sattigeri, P. (2025). Evaluating the prompt steerability of large language models. En *Proceedings of the 2025 Conference of the Nations of the Americas Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL 2025)* (pp. 7874–7900). Association for Computational Linguistics. <https://aclanthology.org/2025.naacl-long.400/>
- Mullainathan, S., & Shafir, E. (2013). *Scarcity: Why having too little means so much*. Times Books/Henry Holt.
- Newcombe, R. G. (1998). Interval estimation for the difference between independent proportions: Comparison of eleven methods. *Statistics in Medicine*, 17(8), 873–890. [https://doi.org/10.1002/\(SICI\)1097-0258\(19980430\)17:8<873::AID-SIM779>3.0.CO;2-I](https://doi.org/10.1002/(SICI)1097-0258(19980430)17:8<873::AID-SIM779>3.0.CO;2-I)
- O'Donoghue, T., & Rabin, M. (1999). Doing it now or later. *American Economic Review*, 89(1), 103–124. <https://doi.org/10.1257/aer.89.1.103>
- Olsen, R., Macaskill, A., & Hunt, M. (2024). Episodic future thinking only reduces delay discounting when future events involve the self. *Journal of Behavioral Decision Making*, 37(4), e2397. <https://doi.org/10.1002/bdm.2397>
- Park, J. S., O'Brien, J. C., Cai, C. J., Morris, M. R., Liang, P., & Bernstein, M. S. (2023). Generative agents: Interactive simulacra of human behavior. En *Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology (UIST '23)* (Artículo 2, pp. 1–22). ACM. <https://doi.org/10.1145/3586183.3606763>

- Park, J. S., Zou, C. Q., Kamphorst, J., Egan, N., Shaw, A., Hill, B. M., Cai, C., Morris, M. R., Liang, P., Willer, R., & Bernstein, M. S. (2024). Generative agent simulations of 1,000 people [Preprint]. arXiv. <https://arxiv.org/abs/2411.10109>
- Pratelli, M., & Petrocchi, M. (2025). Evaluating the simulation of human personality-driven susceptibility to misinformation with LLMs [Preprint]. arXiv. <https://arxiv.org/abs/2506.23610>
- Rao, A. S., & Georgeff, M. P. (1995). BDI agents: From theory to practice. En *Proceedings of the First International Conference on Multi-Agent Systems (ICMAS-95)* (pp. 312–319). AAAI Press.
- Rösch, S. A., Stramaccia, D. F., & Benoit, R. G. (2022). Promoting farsighted decisions via episodic future thinking: A meta-analysis. *Journal of Experimental Psychology: General*, 151(7), 1606–1635. <https://doi.org/10.1037/xge0001148>
- Ross, J., Kim, Y., & Lo, A. W. (2024). LLM economicus? Mapping the behavioral biases of LLMs via utility theory. En *Conference on Language Modeling (COLM 2024)*. <https://arxiv.org/abs/2408.02784>
- Salvi, F., Horta Ribeiro, M., Gallotti, R., & West, R. (2025). On the conversational persuasiveness of GPT-4. *Nature Human Behaviour*. Publicación anticipada en línea. <https://doi.org/10.1038/s41562-025-02194-6>
- Shanahan, M., McDonell, K., & Reynolds, L. (2023). Role play with large language models. *Nature*, 623(7987), 493–498. <https://doi.org/10.1038/s41586-023-06647-8>
- Shinn, N., Cassano, F., Berman, E., Gopinath, A., Narasimhan, K., & Yao, S. (2023). Reflexion: Language agents with verbal reinforcement learning. *Advances in Neural Information Processing Systems 36 (NeurIPS 2023)*. <https://arxiv.org/abs/2303.11366>
- Slumbers, O., Leibo, J. Z., & Janssen, M. A. (2025). Using large language models to simulate human behavioural experiments: Port of Mars. arXiv. <https://arxiv.org/abs/2506.05555>
- Tesfatsion, L. (2006). Agent-based computational economics: A constructive approach to economic theory. En L. Tesfatsion & K. L. Judd (Eds.), *Handbook of computational economics* (Vol. 2, pp. 831–880). North-Holland. [https://doi.org/10.1016/S1574-0021\(05\)02016-2](https://doi.org/10.1016/S1574-0021(05)02016-2)
- Thaler, R. H., & Benartzi, S. (2004). Save more tomorrow: Using behavioral economics to increase employee saving. *Journal of Political Economy*, 112(S1), S164–S187. <https://doi.org/10.1086/380085>
- Train, K. E. (2009). *Discrete choice methods with simulation* (2nd ed.). Cambridge University Press.
- Trope, Y., & Liberman, N. (2010). Construal-level theory of psychological distance. *Psychological Review*, 117(2), 440–463. <https://doi.org/10.1037/a0018963>
- Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., Chen, Z., Tang, J., Chen, X., Lin, Y., Zhao, W. X., & Wei, Z. (2024a). A survey on large language model based autonomous agents. *Frontiers of Computer Science*, 18(6), 186345. <https://doi.org/10.1007/s11704-024-40231-1>
- Wang, L., Zhang, J., Yang, H., Chen, Z., Tang, J., Zhang, Z., Chen, X., Lin, Y., Song, R., Zhao, W. X., Xu, J., & Dou, Z. (2024b). User behavior simulation with large language model-based agents. *ACM Transactions on Information Systems*, 43(2), Article 53. <https://doi.org/10.1145/3708985>
- Wang, P., Li, L., Chen, L., Cai, Z., Zhu, D., Lin, B., Cao, Y., Kong, L., Liu, Q., Liu, T., & Sui, Z. (2024). Large language models are not fair evaluators. En *Proceedings of the 62nd Annual*

- Meeting of the Association for Computational Linguistics (ACL 2024) (pp. 9440–9450).
<https://aclanthology.org/2024.acl-long.511/>
- Xi, Z., Chen, W., Guo, X., He, W., Ding, Y., Hong, B., & Gui, T. (2023). The rise and potential of large language model based agents: A survey (arXiv:2309.07864). arXiv.
<https://arxiv.org/abs/2309.07864>
- Xie, C., Chen, C., Jia, F., Ye, Z., Lai, S., Shu, K., Gu, J., Bibi, A., Hu, Z., Jurgens, D., Evans, J., & Torr, P. (2024). Can large language model agents simulate human trust behavior? *Advances in Neural Information Processing Systems (NeurIPS 2024)*.
<https://openreview.net/forum?id=CeOwahuQic>
- Xu, W., Liang, Z., Mei, K., Gao, H., Tan, J., & Zhang, Y. (2025). A-Mem: Agentic memory for LLM agents. *Advances in Neural Information Processing Systems (NeurIPS 2025)* (arXiv:2502.12110). <https://arxiv.org/abs/2502.12110>
- Ye, J.-Y., Ding, Q.-Y., Cui, J.-F., Liu, Z., Jia, L.-X., Qin, X.-J., Xu, H., & Wang, Y. (2022). A meta-analysis of the effects of episodic future thinking on delay discounting. *Quarterly Journal of Experimental Psychology*, 75(10), 1876–1891. <https://doi.org/10.1177/17470218211066282>
- Yeung, K. (2017). ‘Hypernudge’: Big Data as a mode of regulation by design. *Information, Communication & Society*, 20(1), 118–136. <https://doi.org/10.1080/1369118X.2016.1186713>
- Yuan, J., Li, H., Ding, X., Xie, W., Li, Y.-J., Zhao, W., Wan, K., Shi, J., Hu, X., & Liu, Z. (2025). Understanding and mitigating numerical sources of nondeterminism in LLM inference. arXiv.
<https://arxiv.org/abs/2506.09501>
- Zhu, J.-Q., Yan, H., & Griffiths, T. L. (2024). Language models trained to do arithmetic predict human risky and intertemporal choice [Preprint]. arXiv.
<https://doi.org/10.48550/arXiv.2405.19313>

10. Anexos

ANEXO A. ARQUITECTURA DEL SISTEMA DE INTERVENCIÓN INTELIGENTE

Figura A.1. Instrucciones de inicialización de los perfiles extremos del espectro de presentismo.

PERFIL LEVE · β esperado $\approx 0,9$	PERFIL SEVERO · β esperado $< 0,5$
«Eres una persona de 38 años, contadora, con un fondo de emergencia equivalente a seis meses de gastos y un plan de ahorro mensual automático para el retiro. Vives cómoda, sin deudas. Piensas las decisiones financieras antes de tomarlas y te molesta gastar de más en cosas que no planeaste. Tu horizonte mental es de años: piensas en cómo se ve tu vida en 5 a 10 años cuando tomas decisiones. La urgencia inmediata no es algo que sientas con frecuencia. No eres avara, pero rara vez te dejas llevar por el 'lo quiero ahora'.»	«Eres una persona de 26 años, freelancer con ingresos irregulares; vives al día. Tienes dos deudas activas: una tarjeta de crédito al 95% de tasa nominal anual y un préstamo personal con cuota mensual que se siente cada mes. Si te ofrecen dinero ya, lo piensas en función de qué urgencia puedes tapar este mes —un servicio cortado, un alquiler, comida—. No tienes ahorro. Piensas día a día, semana a semana. 'Después veo' es tu frase recurrente cuando alguien te habla de planes a 6 meses o más. Sientes ansiedad cuando ves cuentas pendientes.»

Fuente: Elaboración propia.

Variantes del preámbulo EFT

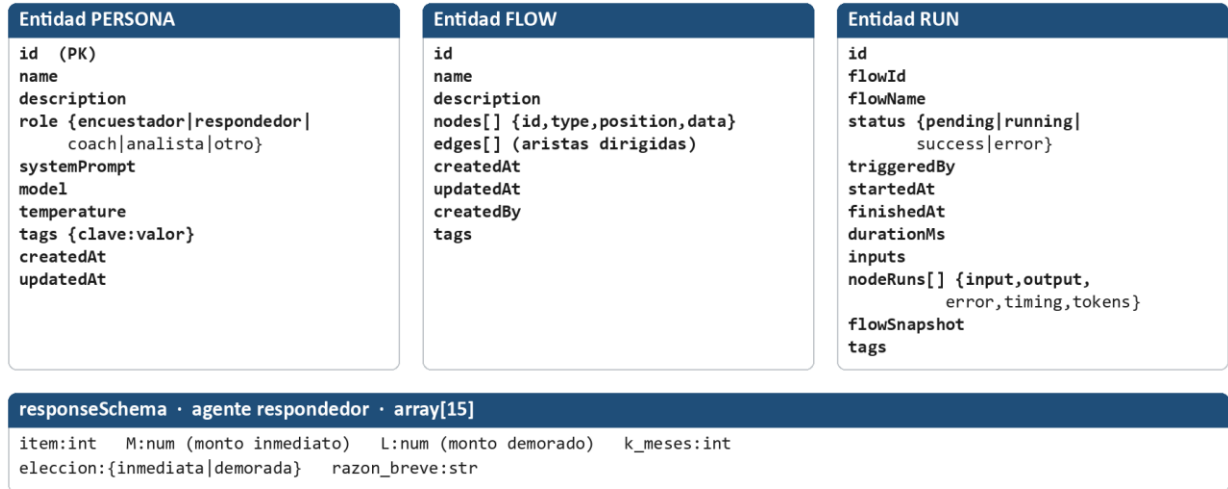
Figura A.2. Variantes del preámbulo EFT evaluadas (la variante pérdida es la intervención principal).

NEUTRA	POSITIVA · recompensa futura
«Antes de responder, haz este ejercicio mental por 30 segundos: imagínate vívidamente a ti misma dentro de 12 meses. ¿Dónde estás? ¿Qué necesitas? ¿Qué te aliviaría tener ese dinero entonces? Visualiza una escena concreta: tu futuro yo en una situación específica donde ese dinero adicional importa. Siente qué pensaría esa versión tuya al recordar la decisión que tomas hoy. Ahora, con esa imagen presente, responde los 15 ítems.»	«Antes de responder, dedica 30 segundos a este ejercicio mental: imagina vívidamente cómo te sentirás al RECIBIR los montos demorados. Ponte en una escena concreta dentro de 6, 12 o 24 meses según el ítem. Visualiza el momento en que recibes el dinero diferido: ¿qué haces con esa cantidad mayor? ¿qué problema te resuelve? ¿qué alivio o satisfacción sientes? Hazlo sensorial: el lugar, la hora, qué piensas cuando ves el monto en tu cuenta. Con esa sensación de gratificación futura presente, responde los 15 ítems.»
PÉRDIDA · intervención principal	CONCRETA · visualización episódica
«Antes de responder, dedica 30 segundos a imaginar a tu yo del FUTURO mirando hacia atrás. Piensa en tu yo dentro de 12 o 24 meses revisando estas decisiones. Si eligieras siempre lo inmediato (la opción más chica), ¿qué te diría tu yo futuro al verse con menos dinero acumulado? ¿qué reproche se haría? Imagina la cara de tu yo futuro, la voz interior diciéndote '¿por qué no esperé esa vez?'. Ahora responde cada ítem con esa anticipación de arrepentimiento presente.»	«Antes de cada decisión, haz esta visualización episódica: imagina una escena específica de tu vida en el momento del pago demorado. Si el ítem dice USD 280 en 24 meses, proyéctate concretamente dos años hacia adelante: ¿dónde vives? ¿con quién estás? ¿qué hora del día es cuando ves el ingreso? Pinta la escena con detalle sensorial: el lugar específico, la luz, qué haces justo después de recibirlo. Tómate 10 segundos de esta visualización antes de cada ítem. Con esa imagen episódica presente, decide.»

Fuente: Elaboración propia.

Esquema de almacenamiento persistente

Figura A.3. Modelo de datos del marco experimental (entidades de persistencia y esquema de respuesta del agente).



Persistencia: objetos JSON en R2 (Cloudflare) · A-MEM y trazas en tablas eft_adp_* / eft_lng_*

Fuente: Elaboración propia.

Parámetros de inferencia y reproducibilidad (detalle)

Tabla A.2.1. Parámetros de inferencia del modelo generador de decisiones Gemini por componente.

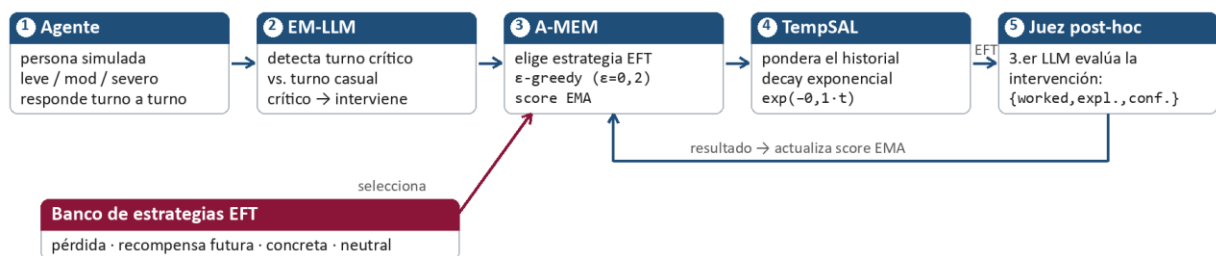
Componente	Modelo	Temperatura	Salida estructurada
Agente respondedor (batería de 15 ítems)	gemini-3.1-flash-lite	0,6	Sí (JSON Schema)
Analista β - δ (post-batería)	gemini-3.1-flash-lite	0,2	Sí (JSON Schema)
Generador EFT (sistema adaptativo H2)	gemini-3.1-flash-lite	0,8	Sí (JSON Schema)
Juez EM-LLM (detección de evento crítico, H2)	gemini-3.1-flash-lite	0,1	Sí (JSON Schema)
Analista posterior (mecanismo adaptativo H2)	gemini-3.1-flash-lite	0,2	Sí (JSON Schema)

Fuente: Elaboración propia.

ANEXO B. EVALUACIÓN DEL SISTEMA INTELIGENTE Y EL CAMBIO DEL β

B.1 Arquitectura de la validación funcional

Esquema B.1. Arquitectura de la validación funcional: el mecanismo adaptativo.



Bucle adaptativo · 4 agentes Gemini con salida estructurada · persistencia en tablas eft_adp_*

Fuente: Elaboración propia.

B.2 Diseño del experimento del sistema adaptativo

Tabla B.2. Diseño del experimento del sistema adaptativo.

Etapa	Perfiles	Condiciones	Motor	Idiomas	Agentes/subgrupo
Bucle adaptativo	Leve, moderado, severo	Adaptativo (A-MEM), neutral forzado, regret forzado, conversacional	Gemini 3.1 Flash-Lite	es-neutro, es-EC, en-US	15
Longitudinal (memoria persistente)	Leve, moderado, severo	Tratamiento vs. control	Gemini 3.1 Flash-Lite	es-neutro, es-EC, en-US	12 + 12

Fuente: Elaboración propia.

B.3 Resultados del mecanismo adaptativo por perfil y condición

Tabla B.3. Tasa de reversión de la decisión por perfil y condición (español neutro).

Perfil	Adaptativo (A-MEM)	Neutral forzado	Regret forzado	Conversacional
Leve	—	—	—	—
Moderado	91,1%	0,4%	93,8%	100,0%
Severo	0,0%	0,0%	0,0%	0,0%

Fuente: Elaboración propia.

Nota. Reversión: proporción de decisiones críticas que viran de la opción inmediata a la demorada tras la intervención. El perfil leve no presenta decisiones críticas en el rango evaluado (límite superior de paciencia).

B.4 Aprendizaje de estrategias (A-MEM)

Tabla B.4. Puntuación final de A-MEM por estrategia (perfil moderado; arranque en empate 0,5).

Estrategia	Puntuación final
Anticipación del arrepentimiento	0,89
Recompensa futura	0,65
Visualización concreta	0,58
Neutral	0,43

Fuente: Elaboración propia.

B.5 Robustez intercultural del cambio del β

Tabla B.5. Cambio del β ($\Delta\beta$, control \rightarrow EFT) por perfil e idioma.

Perfil	es-neutro	es-EC	en-US
Leve	+0,003	0,000	0,000
Moderado	+0,125	+0,174	+0,139
Severo	+0,311	+0,388	+0,523

Fuente: Elaboración propia.

B.6 Experimento longitudinal con memoria persistente

Tabla B.6. Proporción de decisiones pacientes por sesión: tratamiento (T) vs. control (C), español neutro.

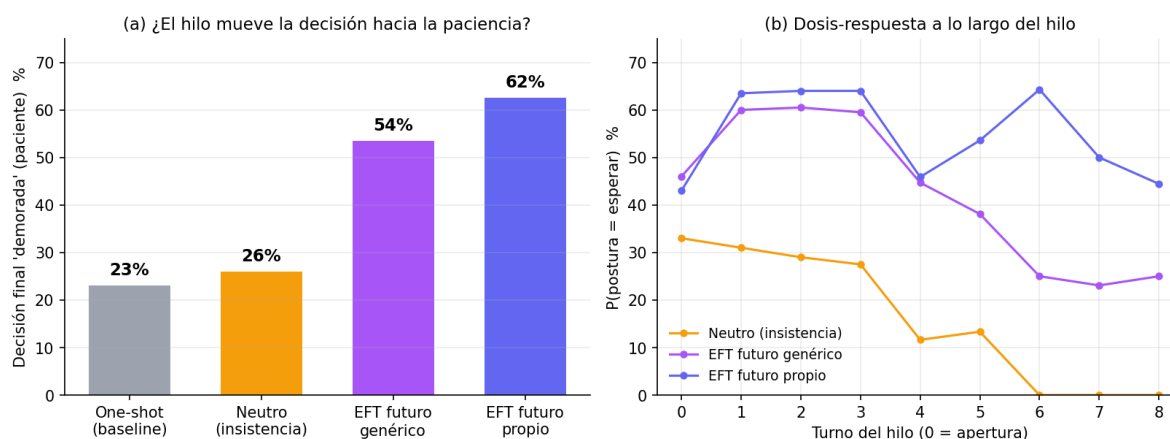
Perfil	Grupo	S1	S2	S3	S4	S5
Moderado	T	0,61	0,74	0,79	0,83	0,80
Moderado	C	0,61	0,60	0,61	0,61	0,58
Severo	T	0,00	0,14	0,18	0,27	0,09
Severo	C	0,00	0,00	0,00	0,00	0,00

Fuente: Elaboración propia.

Nota. T: tratamiento; C: control con memoria idéntica sin intervención. El perfil leve se omite por permanecer en 1,00 (saturación) en ambos grupos.

B.7 Hilo conversacional: control de la complacencia

Figura B.1. Experimento de conversación de varios turnos. (a) Tasa de decisión paciente final por grupo: el reencuadre EFT casi triplica la paciencia respecto del línea de base, mientras la insistencia neutra apenas la mueve. (b) Respuesta por turno: la probabilidad de postura paciente se eleva temprano y se sostiene en los grupos EFT, y decae en el neutro.



Fuente: Elaboración propia.

ANEXO C. ANÁLISIS CUALITATIVO DE LAS INTERVENCIONES GENERADAS

Tabla C.1. Distribución de temas en las razones verbales (% de decisiones).

Subgrupo	Futuro	Precaución	Necesidad	Impulso
Leve · control	68%	24%	2%	2%
Leve · EFT	n/c*	n/c*	2%	n/c*
Moderado · control	49%	34%	6%	25%
Moderado · EFT	50%	29%	6%	25%
Severo · control	63%	30%	23%	16%
Severo · EFT	48%	33%	20%	15%

Fuente: Elaboración propia.

Nota. n/c: no se interpreta la frecuencia temática del subgrupo leve-EFT por la saturación de la respuesta; no representa un dato faltante.