#69

Observatorio de Divulgación Financiera

Octubre 2026
Depósito legal: B 21662-2012

DOCUMENTO DE TRABAJO

Clientes sintéticos, decisiones reales: cómo la IA está transformando la investigación en banca

Paola Schietekat
Olympia Arango

IEF Instituto de Estudios Financieros
Research Institute

Caixa Enginyers FUNDACIÓ

Abstract

El objetivo de este artículo es introducir el concepto de participantes sintéticos (generados mediante IA) que simulan respuestas, opiniones y procesos de decisión humano, ayudando así a la investigación en el ámbito del comportamiento de las personas. Para ejemplificar la implementación de estos participantes se explica un caso de aplicación dentro del mundo del sector bancario por parte de la consultora Neovantas.

Referencias circulares: Participantes Sintéticos, Economía Conductual, Inteligencia Artificial (IA), Comportamiento humano, Piloto experimental, Sector Bancario, Economía Experimental.

Aclaración: Por motivos de confidencialidad los datos y parte de los *insights* del estudio han sido sanitizados.

1. Introducción al estudio del comportamiento humano en la economía

Una de las grandes limitaciones que marcan el desarrollo e implementación de cualquier tipo innovación es el impacto que tendrá entre aquellos que la recibirán, es decir, cómo será percibido ese cambio. En el fondo, se trata de una cuestión puramente comportamental: la decisión sobre si lanzar o no una campaña de publicidad nueva, un producto, un diseño, una estrategia de *pricing* o una política pública dependerá de la respuesta a la siguiente pregunta ¿cómo lo percibirá el cliente, mercado o ciudadanía? Nos enfrentamos al siguiente desafío: ¿cómo prever o aproximar la reacción humana a alguna novedad o cambio?

Para dar respuesta a esta pregunta una de las soluciones conocidas hasta ahora son los pilotos experimentales. Se trata de un testeo del propio lanzamiento, es decir, a pequeña escala, ir probando como algunas personas, por ejemplo, clientes, pueden reaccionar a esos cambios: productos, campañas, ajustes en el precio y oferta, etc. Se trata de replicar el método científico mediante prueba y error para ajustar la propuesta de la mejor manera a lo que requiere el sector poblacional que va a recibirla. A pesar de que esta metodología es buena y permite a las empresas, instituciones y entidades prever el potencial impacto de una nueva iniciativa, es costosa, ya que lanzar un piloto, implementarlo y analizar sus resultados requiere tiempo y presupuesto.

Con la irrupción de la IA se presenta una ventana de oportunidades para este tipo de experimentaciones que pretende dar respuesta al problema de su coste: ¿cómo logramos una aproximación real a la potencial respuesta humana a una innovación? Sea esta un nuevo producto u cualquier tipo de cambio institucional u organizacional. El desarrollo de participantes sintéticos, es decir, la generación de identidades generadas por IA que den respuesta y reaccionen a esos cambios o iniciativas propuestas, estando ajustadas y calibradas a la realidad de la población y a su contexto sectorial concreto, permitirían afinar mejor la implementación de pilotos y ahorrar a los actores que los usen tiempo y recursos.

Este es precisamente el objetivo del presente artículo, desarrollar un marco conceptual para explicar qué son los participantes sintéticos, por qué son relevantes en el desarrollo de la innovación, pilotos e iniciativas y más precisamente en el sector de la Economía Conductual. En concreto, nos centraremos en el estudio del uso de los participantes sintéticos dentro del sector bancario, exponiendo no solo su marco teórico y de aplicación, sino que también un caso práctico llevado a cabo.

2. El estudio del comportamiento mediante el uso de la IA

2.1 Definición y marco de análisis de la Economía Conductual

Tal y como hemos mencionado al principio, el problema al que se enfrentan investigadores, analistas y gurús de la innovación es saber cuál es el cambio a accionar para que la población expuesta reaccione favorablemente, es decir, se trata puramente de una cuestión conductual: cómo va a ser percibido ese cambio y qué se necesita para que sea implementado. Para entender la vertiente psicológica, pero a la vez económica, de este fenómeno es necesario adherirse a los principios de la Economía Conductual, una ciencia relativamente joven que busca entender las motivaciones, percepciones y explicaciones detrás del comportamiento humano, especialmente cuando se habla de decisiones económicas o financieras.

Partimos de la base de los modelos clásicos de la economía para comprender cómo tomamos decisiones los humanos. Estos asumen que las personas tomamos decisiones de manera racional (Kahneman, 2011). Esta racionalidad cognitiva responde a una serie de principios que consideran que las personas escogemos la opción que siempre más nos beneficia, haciendo una especie de cálculo de coste beneficio. La realidad se aleja un poco de esa máxima, ya que, por una simple cuestión evolutiva, no podemos analizar todas las decisiones de la misma manera ni dedicándole los mismos recursos, ya que no tenemos tiempo para ello y al día tomamos demasiadas decisiones, miles de ellas, por lo tanto, debemos *escoger u optimizar* aquellas a las que dedicaremos más recursos o tiempo de análisis, pero ¿cómo se *escoge*? Es en este punto en el que irrumpe la Economía Conductual para explicarnos cómo

se desarrolla a nivel cognitivo, es decir, mental, ese proceso de optimización y elección.

La Economía Conductual se define como la intersección entre economía y psicología. Se trata de una rama del conocimiento que estudia cómo tomamos decisiones las personas, cómo los incentivos, el contexto y la manera de presentar las opciones impactan en cómo nosotros las percibimos y por ende en su elección. Hace más de 20 años se otorgaba uno de los primeros premios Nobel a uno de los principales impulsores de la Economía Conductual, Daniel Kahneman. Sus investigaciones arrojaron luz al proceso por el cual las personas toman decisiones, adoptando un término más común en psicología que en economía, pero que cada vez se está popularizando más en el entorno económico: sesgo cognitivo. Este concepto se define como los atajos mentales que toma nuestro cerebro para decidir de manera más rápida (Tversky & Kahneman, 1974).

Un ejemplo de sesgo cognitivo es el sesgo de anclaje. Explica cómo una primera información recibida puede influir en nuestras decisiones posteriores. Por ejemplo, cuando una tienda muestra una chaqueta con un precio original de 200 € y posteriormente indica que está rebajada a 120 €, muchas personas perciben la compra como una oportunidad, aunque no tengan información suficiente para determinar si 120 € es realmente un precio adecuado. En este caso, el primer valor observado actúa como una referencia mental que condiciona la valoración del producto (Tversky & Kahneman, 1974), se trata de una expectativa en la que la persona que la percibe se *ancla,* en consecuencia.

Otro ejemplo es el denominado efecto marco o *framing effect,* que muestra cómo la forma en la que se presenta una misma información puede modificar nuestra percepción al respecto y nuestra toma de decisiones. Por ejemplo, un tratamiento médico puede comunicarse indicando que tiene una tasa de éxito del 90% (marco de explicación positivo) o, alternativamente, que existe un 10% de probabilidad de fracaso (marco de explicación negativo). Aunque ambas afirmaciones transmiten exactamente la misma información, la percepción y la respuesta de las personas pueden cambiar dependiendo de la manera en la que se formula el mensaje (Tversky & Kahneman, 1979).

Un último ejemplo de aplicación de la Economía Conductual es su estudio del impacto temporal en nuestra percepción. Esta ciencia también explica por qué en muchas ocasiones las personas tomamos decisiones que entran en conflicto con nuestros propios objetivos a largo plazo. Un caso es la dificultad para ahorrar para la jubilación, aunque muchas personas son conscientes de la importancia de reservar dinero para el futuro, algunas de ellas tienden a priorizar el consumo inmediato, es decir el gasto actual, porque les genera mayor satisfacción inmediata en comparación a imaginarse los beneficios futuros de ahorrar precisamente esa cantidad. Este fenómeno se conoce como sesgo del presente y refleja cómo nuestras preferencias pueden estar influidas por la tendencia a valorar más aquello que obtenemos en el presente frente a aquello que podríamos recibir en el futuro (Thaler, 2015).

Partiendo de la base que los estudios de la Economía Conductual nos explican que la racionalidad asumida por los modelos de economía clásica no describiría tan bien como esperamos el comportamiento humano, sería lógico pensar que los modelos conductuales que incluyen variables psicológicas y comportamentales nos permiten aproximarnos mejor a cómo pensamos, qué hacemos y por qué. Siendo así, para entender el comportamiento económico nos ajustaremos a estos modelos más recientes y a su intersección con la IA para comprender avances en la experimentación y estudio de la toma de decisiones humana[1].

2.2 La Inteligencia Artificial como catalizador del comportamiento humano

Los avances de la Economía Conductual y las Ciencias del Comportamiento han permitido desarrollar marcos cada vez más sofisticados para comprender y modelar la toma de decisiones humanas, mientras que los recientes avances en Inteligencia Artificial generativa han abierto la posibilidad de trasladar estos conocimientos a agentes capaces de simular y reproducir determinados patrones de comportamiento humano (Park et al., 2023). La investigación y desarrollo de experimentos sobre cómo tomamos decisiones las personas permite establecer patrones e incluso aproximarnos a predecir o anticipar lo que potencialmente podríamos hacer. Siendo capaces de entender cómo tomamos decisiones las personas, trasladar este conocimiento a una herramienta de IA permite generar participantes sintéticos para su réplica[2].

Los avances de la Economía Conductual han permitido no solo describir cómo decidimos las personas, sino sistematizar esos patrones con suficiente detalle como

[1]Cabe destacar que actualmente dentro de los estudios de Economía Conductual se habla de racionalidad evolutiva y ecológica (Todd y Gigerenzaer, 2007; Vanberg, 2004), aquella que incluye los aspectos psicológicos y avances de las ciencias cognitivas.

[2]Es importante precisar que un participante sintético no es un gemelo digital. Un gemelo digital replica a un individuo real concreto a partir de su historial de datos mientras que un participante sintético se genera a partir de distribuciones poblacionales y conocimiento conductual codificado, sin representar a una persona real en particular.

para intentar reproducirlos. Décadas de experimentación han documentado con precisión una taxonomía de sesgos y heurísticas que operan de forma regular y, hasta cierto punto, predecible. Esto abre la puerta a su aplicación en la Inteligencia Artificial: si el comportamiento humano sigue patrones identificables, un sistema entrenado sobre grandes volúmenes de conducta humana debería, en principio, reproducir esos mismos patrones.

Sobre esa premisa surgen los participantes sintéticos. Se trata de agentes generados mediante inteligencia artificial, habitualmente a partir de grandes modelos de lenguaje (LLMs), diseñados para simular las respuestas, opiniones y procesos de decisión de individuos humanos, y utilizados como alternativa o complemento a las muestras humanas en distintos contextos de investigación (Arora et al., 2025; MRS, 2024). A diferencia de un simple generador de datos aleatorios, un participante sintético busca emular a un sujeto al dotársele de un perfil y pedirle que reaccione, opine o elija como lo haría una persona con esas características.

La evidencia más relevante sobre la capacidad de estos agentes para representar el comportamiento humano proviene precisamente de los estudios que examinan si reproducen los sesgos y heurísticas documentados por la literatura conductual. Los hallazgos muestran que, en algunos casos, los modelos replican fielmente los sesgos humanos, en otros los amplifican y en otros incluso los invierten, mostrando desviaciones que un ser humano difícilmente exhibiría (Stamatogiannakis et al., 2025; Cheung, Maier, & Liedera, 2025; Dillion et al., 2023). A ello se suma una notable sensibilidad al *prompt*: la fraseología, la elección de palabras y el formato del *prompt* pueden alterar de forma significativa las respuestas del modelo (Tjuatja et al., 2024). Un experimento que evaluó la profundidad de razonamiento de varios modelos mediante un juego de solicitud de dinero ilustra bien estos límites ya que destacó maleabilidad ante el *prompt*, un sesgo de equidad inducido por el propio entrenamiento del modelo y un "efecto de demanda" por el cual los modelos imitaban los ejemplos que se les proporcionaban (Gao et al., 2025).

Esta doble naturaleza de agentes que reflejan el comportamiento humano, pero de manera imperfecta y a veces distorsionada, es lo que define la sinergia entre la Economía Conductual y los participantes sintéticos. Por un lado, la disciplina aporta el marco teórico y experimental para diseñar simulaciones con sentido: qué constructos medir, qué mecanismos activar, cómo estructurar una decisión. Por otro, aporta la lente crítica necesaria para interpretar y calibrar los resultados, distinguiendo cuándo el modelo reproduce una regularidad conductual genuina y cuándo simplemente devuelve un artefacto de su entrenamiento. Los participantes sintéticos no sustituyen el conocimiento conductual, sino que lo requieren como condición para ser útiles.

3. Dónde se están usando los participantes sintéticos y por qué son relevantes para las entidades financieras

En pocos años, los participantes sintéticos han pasado de ser una curiosidad académica a una herramienta aplicada en la investigación de mercados, el marketing, el diseño de productos y la gestión de la experiencia de cliente (Arora et al., 2025; Doudkin et al., 2025; MRS, 2024). Su atractivo radica en que permiten obtener grandes volúmenes de datos a una velocidad mayor y un coste menor a las muestras humanas, y hacen posible explorar escenarios que serían logística o éticamente complicados de plantear con personas reales, desde acceder a poblaciones difíciles de reclutar hasta simular condiciones de mercado extremas (Aher et al., 2023; Cui et al., 2025).

En la práctica, estas capacidades se traducen en varios usos concretos. Los participantes sintéticos se emplean para simular dinámicas cualitativas al estilo de un *focus group*, testar mensajes y piezas creativas antes de su lanzamiento, y anticipar cómo reaccionarían distintos perfiles ante un cambio de producto o de comunicación. Dos estudios resultan especialmente ilustrativos de su potencial. En pruebas de usabilidad (UX), un modelo multimodal identificó entre el 73% y el 77% de los problemas de una interfaz, superando el 57%-63% detectado por evaluadores humanos expertos (Zhong et al., 2025). En investigación de marketing, un enfoque híbrido humano-IA encontró que las respuestas cualitativas generadas por el modelo eran superiores en profundidad y riqueza de *insight* a las de sus contrapartes humanas (Arora et al., 2025).

El valor de fondo, sin embargo, no está tanto en sustituir la investigación tradicional como en antecederla. Al permitir un prototipado rápido antes de desplegar un estudio con humanos, los participantes sintéticos

ayudan a reducir tiempos, generar y depurar hipótesis, y priorizar iniciativas antes de comprometer el presupuesto de un piloto o una encuesta a gran escala (Arora et al., 2025; MRS, 2024). En lugar de llegar al campo con preguntas abiertas, el investigador llega con hipótesis ya afinadas sobre qué mensajes, atributos o segmentos merecen ser explorados.

(1) relevancia en banca por la complejidad de las decisiones financieras riesgo, incertidumbre, horizonte temporal y carga emocional.

(2) aplicación a decisiones de ahorro, inversión, contratación y fidelización.

Este potencial convive con un conjunto de riesgos que la literatura documenta con creciente claridad y que conviene reconocer antes de aplicar estas herramientas a un problema real. En el plano metodológico, los agentes sintéticos tienden a inflar los tamaños de efecto con valores hasta dos o tres veces superiores a los de los estudios con humanos y a producir distribuciones de respuesta demasiado estrechas, que no capturan la heterogeneidad de las poblaciones reales (Doudkin et al., 2025; Ustiyanovych & Krpan, 2025; Stamatogiannakis et al., 2025). En el plano epistemológico, preocupa la equivalencia funcional versus la equivalencia mecanística; es decir, que un razonamiento humano y uno artificial puedan llegar al mismo resultado por procesos completamente distintos. Por otra parte, resalta la falacia del antropomorfismo, que lleva a olvidar que estos modelos son sistemas estadísticos autorregresivos, no sujetos con creencias ni intenciones. Por lo tanto, los outputs de un modelo no pueden equipararse al cien por ciento a un comportamiento y sus motivaciones subyacentes. (Shanahan et al., 2023; Lin, 2025; Mitchell & Krakauer, 2023). Y en el plano ético, los modelos rinden sistemáticamente mejor para poblaciones anglófonas y occidentales (las llamadas WEIRD), tienden a estereotipar a los grupos representados a partir de etiquetas demográficas simples y corren el riesgo de aplanar la diversidad de las poblaciones que pretenden representar (Amini, 2025; Qu & Wang, 2024; Agnew et al., 2024; MRS, 2024).

La conclusión que se desprende de la literatura no es que los participantes sintéticos deban descartarse, sino que su valor depende por completo de cómo se diseñen y para qué se utilicen. Usados como sustituto acrítico de la investigación humana, reproducen y amplifican sus propios sesgos; usados como un entorno de experimentación previo, cuidadosamente calibrado y validado, se convierten en un complemento capaz de acelerar y afinar la toma de decisiones. El caso que se presenta a continuación ilustra precisamente esta segunda vía.

4. Caso de uso aplicado a banca

4.1 El reto conductual

Una entidad bancaria internacional dispone de un canal de atención remota que permite a sus clientes resolver gestiones y contratar productos hablando directamente con un asesor especializado, sin necesidad de acudir a una sucursal. Este servicio contacta al cliente con un ejecutivo especializado que puede ejecutar operaciones, ofrecer productos y resolver incidentes con menos fricción, tiempos de espera y sin desplazamientos.

A pesar de que el canal telefónico puede atender de igual o mejor forma los requerimientos de los clientes, muchos aún prefieren dirigirse a la sucursal física. Esto plantea la pregunta central de la investigación: si el canal funciona, ¿por qué los clientes no migran hacia él?

Identificar a profundidad las preferencias de los clientes requiere un estudio de mercado que implica tiempo y presupuesto: diseño del instrumento, reclutamiento del panel, levantamiento y análisis. Realizar un ejercicio con participantes sintéticos antes de lanzar un estudio a gran escala permite identificar preferencias, actitudes, mitos y barreras para así desarrollar hipótesis a validar con la muestra humana. Las muestras sintéticas también facilitan hacer un muestreo preciso, generando los perfiles de interés que un muestreo de panel normalmente tarda en reclutar.

4.2 El desarrollo de un participante sintético

El ejercicio generó una muestra de N=1.000 participantes sintéticos diseñada para reflejar clientes bancarios de entre 20 y 64 años con unos ingresos mensuales de entre 800 y 8.000 euros aproximadamente, siendo todos usuarios de la aplicación bancaria. Para el muestreo se establecieron cuotas de edad, género, región e ingresos basadas en las distribuciones de datos sociodemográficos lo más actualizados posibles.

Las encuestas nacionales que se utilizaron para derivar las distribuciones poblacionales incluyen datos de educación e inclusión financiera, por lo que fue posible incluir variables de comportamiento financiero y actitudes hacia el dinero. Después de una validación inicial, se enriquecieron los perfiles sociodemográficos con una base cultural, una base conductual y una de usabilidad.

De esta forma, cada participante se convierte en un perfil de cuatro capas, cada una pudiendo ser auditada y validada de manera independiente:

- **Agente sociodemográfico:** Genera el *shell*[3] de cada participante haciendo cumplir las cuotas del estudio, garantizando que la muestra reproduzca la estructura poblacional del *target* y agregando los datos de comportamiento financiero encontrados para ese entorno y región concreta.

Partir de distribuciones poblacionales reales diferencia un estudio defendible de una simulación circular. La investigación sobre muestras sintéticas muestra que los modelos de lenguaje contienen sesgos que muchas veces están correlacionados con la demografía: cuando se condiciona el modelo con perfiles sociodemográficos reales, es capaz de emular las distribuciones de respuesta de distintos subgrupos con más precisión, suceso que Argyle y sus colegas denominan fidelidad algorítmica (Argyle et al., 2023). Sin ese anclaje, los modelos tienden a sobrerrepresentar a las poblaciones anglófonas, occidentales, jóvenes y de mayor nivel educativo que dominan sus datos de entrenamiento, y a aplanar al resto (Santurkar et al., 2023; Qu & Wang, 2024; Agnew et al., 2024). Hay además una razón práctica: los datos de panel tienden a producir muestras sesgadas respecto a la población general, por lo que no pueden considerarse representativas sin ajustes (Baker et al., 2010). Fijar cuotas a partir de datos de censo permite construir desde el inicio una muestra con la estructura poblacional deseada, en lugar de esperar a que un panel la reclute.

- **Base cultural:** Enriquece los perfiles con una librería cultural a nivel nacional construida a partir de las seis dimensiones de Hofstede. Las seis dimensiones de Hofstede hacen referencia a un modelo de análisis cultural que permite entender los valores y creencias relacionadas la incertidumbre, el poder y otros aspectos sociales en términos nacionales (Hofstede, Hofstede and Minkov, 2010). Además de esta librería cultural, se añadieron datos sobre la percepción de valores y temáticas específicas y relevantes para la región analizada, por ejemplo, la percepción sobre las entidades bancarias. Esta segunda capa conductual más centrada en las puras percepciones y vivencias de la población nacional permite enriquecer los perfiles generados y la sensibilidad del estudio a realidad, teniendo en cuenta específicamente cuáles son los temas relevantes e importantes para la ciudadanía de esa región y en consecuencia para los clientes que la entidad bancaria tiene en esa zona.

Incorporar la cultura de forma explícita responde a una limitación bien documentada de los modelos de lenguaje: su desalineación cultural. Al evaluarlos con el propio instrumento de Hofstede se observa que tienden a alinearse con los valores de Estados Unidos y se adaptan mal a otros contextos culturales (Cao et al., 2023; Masoud et al., 2023). A esto se suma el problema del bloqueo de valores (*value lock-in*) en el que los modelos aprenden sus representaciones de la conducta a partir de datos que son, en esencia, fotografías de un momento dado, por lo que no capturan bien los matices culturales de cada región ni el dinamismo y evolución de estos (Lin, 2025; Agnew et al., 2024). Si no se corrige, un participante sintético razonaría, por defecto, como un usuario promedio estadounidense. Operacionalizar la cultura mediante un marco validado como el de Hofstede y complementarlo con datos de percepción local es lo que permite que los perfiles reflejen un contexto más apegado al de la población estudiada, y no el contexto implícito en el entrenamiento del modelo.

- **Base conductual:** Traduce constructos del modelo de ecuaciones estructurales (SEM) que la literatura vincula con la decisión de migrar de canal. Estos constructos se vinculan con sesgos cognitivos y heurísticas y se codifican para darle a cada perfil un comportamiento coherente con sus características sociodemográficas y conductuales.

Los constructos provienen de la literatura sobre adopción de tecnologías y cambio de comportamiento. Codificar los constructos de manera explícita, en lugar de dejar que el modelo improvise, cumple dos funciones. Primero, preserva la estructura causal del estudio: las puntuaciones de constructo funcionan como las causas de las que se derivan después las respuestas observables. Segundo, hace auditable cada respuesta, porque permite rastrear de qué configuración conductual proviene. Esto conecta con la evidencia de que los modelos de lenguaje reproducen, amplifican o incluso invierten los sesgos humanos de forma poco predecible (Tversky y Kahneman, 1974; Stamatogiannakis et al., 2025): anclar el comportamiento en constructos teóricos reduce ese margen de improvisación y lo somete a una lógica conocida.

- **Base de usabilidad:** Humaniza las respuestas de los perfiles sintéticos al introducir estilos de respuesta (*response styles*) como aquiescencia, neutralidad, consistencia, aleatoriedad, que se observan en las respuestas de encuestados reales.

Los estilos de respuesta son un fenómeno estudiado desde hace décadas en la investigación de mercados. Se definen como la tendencia de una persona a responder de forma sistemática con independencia del contenido del ítem (Baumgartner & Steenkamp, 2001). En encuestas reales introducen variabilidad y, en parte, ruido. Los modelos de lenguaje tienden a lo contrario: producen distribuciones de respuesta demasiado estrechas y respuestas excesivamente coherentes y racionales, que no reflejan la heterogeneidad de las

[3]En este contexto, shell se refiere a la configuración inicial o perfil base de cada participante sintético. Constituye la capa sociodemográfica y contextual sobre la que se construye posteriormente el resto del perfil del participante.

poblaciones humanas (Stamatogiannakis et al., 2025; Doudkin et al., 2025). Reintroducir los estilos de respuesta documentados en la literatura acerca la distribución de los datos sintéticos a la de una muestra humana. En las validaciones de este ejercicio se observó, de hecho, que esta capa no cambiaba la dirección de las respuestas, pero sí añadía la variabilidad que las aproximaba a los patrones reales.

4.3 Resultados e *insights*

La simulación dio como resultado 1.000 encuestas respondidas por usuarios sintéticos, con una distribución de género, edad, nivel educativo, de ingresos, situación laboral y región geográfica acorde con los datos de las encuestas poblacionales más actualizado. Esta representación es difícil de lograr con datos de panel ya que la muestra tiende a concentrarse entre personas de menor nivel socioeconómico, más jóvenes y de la capital del país. Este perfil es el que tiende a responder encuestas en línea, lo que compromete la representatividad de los resultados. La simulación también respetó las cuotas asignadas por banco y uso de aplicación.

Adicionalmente, se hicieron validaciones para asegurar que las respuestas fueran congruentes: que quienes reportaban no usar medios digitales no estuvieran categorizados como usuarios activos de la aplicación, o quienes no fueran clientes de la entidad no contestaran preguntas respecto a su experiencia con servicios del mismo banco. De esta forma, el *output* de la base cultural y de seguridad, un *profile context* en formato de párrafo describiendo a la persona encuestada, coincidiera con sus respuestas en el primer bloque del instrumento. La misma validación se realizó con el *output* de la base conductual, que identificaba los sesgos dominantes en su toma de decisiones financiera, para que sus respuestas en los bloques siguientes coincidieran con sus preferencias y actitudes. Finalmente, se observó que la base de usabilidad no cambiaba la dirección de las respuestas, pero sí añadía más variabilidad en las respuestas, asemejando la distribución de los datos a muestras humanas.

Los resultados del ejercicio experimental permitieron extraer un análisis general sobre el uso de participantes sintéticos para el estudio de las migraciones de usuarios a canales remotos. De hecho, más que identificar una única causa, el estudio permitió comprender cómo distintos efectos psicológicos, como las percepciones sobre el riesgo o los hábitos financieros, impactan en el comportamiento migratorio de un canal bancario de los usuarios

Un elemento clave identificado fue la percepción de fricción o de dificultad en la propia interacción con el canal bancario. Si este se percibe como asumible o no complejo se valora de manera positiva, todos aquellos procesos que impliquen un gasto cognitivo extra o un aprendizaje extra suelen ser descartados o infravalorados por los usuarios. De hecho, la literatura actual sobre estudios de participantes sintéticos confirma el anterior hallazgo, en este caso,

Además de la fricción identificada, un elemento importante que aparece en los resultados del estudio es la confianza. Concretamente, dentro de contextos de digitalización se identifica que no solo la facilidad de uso es relevante para entender el porqué de la migración de un usuario, sino también su percepción sobre seguridad y control del canal al que migran.

Finalmente aparece una dimensión vinculada a la cercanía y hábito del canal remoto. A más experiencias previas positivas relacionadas con entornos digitales, mayor predisposición al cambio (migración) existe. Sesgos cognitivos y efectos psicológicos relacionados con el *status quo* y los cambios de hábitos personales explican este fenómeno (Bandura, 1977).

La realización del ejercicio conductual explicado en este artículo permitió arrojar luz, al menos de manera direccional, al comportamiento humano de los clientes del banco. Las validaciones posteriores realizadas del proyecto mostraron que gran parte de los datos sobre percepciones y creencias fueron capturados correctamente por parte de los participantes sintéticos. Dicha validación se aproximó mediante un análisis comparativo de los resultados de los sintéticos y de comportamiento humano, con una correlación fuerte[4]. A pesar de este primer ejercicio, tanto la entidad bancaria como el equipo de Neovantas y todas aquellas personas involucradas en la investigación sobre los participantes sintéticos son conscientes que este tipo de resultados exigen nuevas capas de validación. Un siguiente paso para seguir podría ser incluir más cantidad de “ruido humano”, es decir, dotar al modelo de lo que entendemos como variabilidad en la toma de decisiones y comportamiento humano, que no tiene necesariamente una explicación clara o estructurada, por ejemplo: inconsistencias en las respuestas o preferencias estrictamente personales. Esta etapa del enriquecimiento no se ha realizado aún debido al potencial gasto que implicaría incluir información tan concreta en el modelo para sofisticarlo aún más. Cabe destacar que con este mismo ejercicio no se busca substituir el comportamiento humano, sino aproximar

[4]Las cifras oficiales del piloto y de validación no pueden compartirse debido a motivos de confidencialidad.

una respuesta similar que permita entenderlo un poco más.

5. Conclusión

El objetivo del presente artículo era acercar al lector al uso de los participantes sintéticos en sectores como el bancario. Para ello hemos realizado un repaso de los modelos de comprensión del comportamiento humano desde la Economía Conductual, para poder alejarnos de la racionalidad teórica clásica que en ocasiones no permite entender bien cómo tomamos decisiones las personas. Partiendo de esa base, entendiendo la toma de decisiones humana como una cuestión contextual y algo más compleja que un cálculo de maximización, presentamos los motivos por los cuáles los avances en herramientas desarrolladas con IA permiten comprender de una manera más completa el comportamiento humano. Los participantes sintéticos son una aproximación lo suficientemente fidedigna como para empezar a entender el comportamiento humano en un entorno "no humano". La principal clave y beneficio del uso de los sintéticos es el ahorro que implican. Poder aproximar y adelantarnos a la percepción humana permite mejorar cualquier tipo de intervención real que queramos efectuar, tanto dentro del mundo bancario como en otros sectores. Así pues, cualquier tipo de intervención que busque una hiperpersonalización, es decir, ajustarse lo máximo posible a la realidad de las personas, se vería beneficiada por el uso de los participantes sintéticos como procedimiento de testeo previo a su implementación. De hecho, se trata de una herramienta que precisamente puede ser muy útil en entornos donde acceder a datos puede ser complejo en el sector bancario, por ejemplo, si el *target* o el usuario no suele responder a pilotos o no tiene predisposición a responder a encuestas o estudios debido a su baja disponibilidad temporal, por ejemplo, los clientes de segmentos más premium.

Cabe destacar que a pesar de sus bonanzas existen una serie de riesgos e implicaciones a tener en cuenta del uso de los participantes sintéticos, si los analizamos desde el punto de vista conductual. En este apartado del artículo veremos tres: el potencial sesgo poblacional, el sesgo de complacencia y la dificultad de replicar cambios bruscos o respuestas extremas.

Como en toda ciencia experimental, sin datos de sectores poblacionales marginados o menos *mainstream* corremos el riesgo de equivocarnos u obtener respuestas poco verídicas al respecto. Dentro de las Ciencias del Comportamiento a este hecho se le conoce como hacer uso de la población *WEIRD (Western, educated, industrialized, rich, and democratic)* y generalizarla, es decir, a partir de una respuesta más "habitual" considerar que está es universal y no incluir variaciones o cambios según otro tipo de variables sociodemográficas. Generalizando los resultados de experimentos conductuales que no incluyen una muestra poblacional diversa ya se incurre en esta limitación, por eso mismo, cabe destacar la importancia de entrenar los modelos de IA con datos diversos que cubran la variabilidad necesaria y diversa de toda la población, evitando que replique los patrones en los que ya caemos en ocasiones dentro de las Ciencias del Comportamiento (Shrestha et al., 2025).

Continuando con el análisis conductual de los riesgos de los participantes sintéticos, existe la posibilidad de que los participantes sintéticos caigan en el sesgo de complacencia, es decir, que a la hora de responder a encuestas o mismamente cuando se usen para desarrollar un estudio tiendan a complacer al entrevistado, dando respuestas que sirvan más para corroborar la hipótesis comportamental que para entender la conducta humana (Ibrahim et al., 2026).

No solo hablamos de complacencia, sino que además los participantes sintéticos suelen fallar en la comprensión y adaptación a un "nuevo comportamiento humano", con esto nos referimos a que el "ruido humano", ya comentado antes suele ser complejo de replicar y es precisamente este hecho el que hace que las respuestas de participantes sintéticos encuentren dificultades a la hora de replicar comportamientos bruscos o opciones extremas.

Es importante tener en cuenta que a día de hoy no existe, hasta donde alcanza el conocimiento de las autoras del presente artículo, un marco regulatorio para el uso de los participantes sintéticos en el ámbito de la Economía Conductua. Existen resultados relevantes dentro de la literatura de los participantes sintéticos, los cuales son explicitados en este artículo, que hablan de la importancia de medir su uso y validez para evitar resultados poco precisos y que generen distorsiones en la compresión del comportamiento humano. A pesar de esta necesidad de definición de un marco regulatorio, iniciativas como el Reglamento de la IA impulsado por la Comisión Europea empiezan a dibujar una primera aproximación para limitar y entender bien la aplicación de herramientas e iniciativas que hacen uso de la Inteligencia Artificial en distintos ámbitos. Sería de esperar que con el paso del tiempo se fueran desarrollando tantos marcos metodológicos desde el mundo académico que permitieran impulsar una propuesta legislativa al respecto.

Más allá de los riesgos e implicaciones previamente es importante mencionar que el uso de los participantes

sintéticos, a pesar de ser innovador y útil, no es un substitutivo de las experimentaciones y estudios con participantes de carne y hueso. Se trata de un catalizador de la investigación del comportamiento humano, lo acelera en todas sus facetas: pilotos experimentales, estudios de laboratorio, observaciones, etc., pero no lo sustituye.

Finalmente, un hecho importante a tener en cuenta en el desarrollo de proyectos con participantes sintéticos es el *trade-off* entre el aumento de la complejidad del modelo, y por ende su mayor aproximación al comportamiento humano, incluyendo toda variabilidad, y los recursos de tiempo y coste que ello implica. Ejecutar simulaciones complejas y que sean lo más realistas posible implica dedicarle mucho tiempo a la comprensión y aproximación de la variabilidad humana previamente mencionada. A la vez, para encajar tal precisión en los modelos, se necesita una gran cantidad de tokens, es decir, recursos económicos que en ocasiones son limitados. Por ello mismo, a lo largo de este artículo se refuerza la idea de que los participantes sintéticos son un muy buen medio para estudiar el comportamiento humano, sin sustituirlo. Se trataría del entrenamiento para una maratón, un proceso que consiste en “empezar a rodar” en la aproximación y comprensión del comportamiento humano para diseñar iniciativas que se adapten mejor a cada uno.

6. Futuras líneas de investigación

El uso de participantes sintéticos no debería evaluarse únicamente por su capacidad para reproducir, en un momento concreto, las medias obtenidas en una muestra humana. El criterio relevante parta entender realmente el impacto que tienen en el mundo de la Economía Conductual y en el caso del sector financiero es su validez fuera de muestra y a lo largo del tiempo. Con esto nos referimos a que, si un modelo sintético se calibra con una muestra humana hoy, debería comprobarse posteriormente con una nueva muestra humana, idealmente recogida en otro momento y sin reajustar el modelo. Este ejercicio de validación permitiría distinguir entre una simple réplica de unas respuestas humanas observadas a una capacidad real de anticipación y análisis de una potencial respuesta de la población. Los resultados de las investigaciones recientes en el territorio del comportamiento humano apuntan hacia el hecho de que algunos modelos de LLMS reproducen de manera correcta y agregada la dirección del comportamiento humano, pero no consiguen replicar su variabilidad. Precisamente por este motivo, un requisito indispensable para realizar cualquier ejercicio con participantes sintéticos es realizar un *benchmarking* humano, es decir, la comparación de las respuestas humanas con las generadas por participantes sintéticos (Sarstedt et al., 2024).

La cuestión temporal añade una dificultad extra. Debido a la propia naturaleza de los participantes sintéticos no se puede asumir que, repitiendo las mismas preguntas meses después, las respuestas hayan cambiado como podrían cambiar la de los humanos de carne y hueso. La literatura especializada en este ámbito apunta hacia dos elementos relevantes cuando se habla de horizonte temporal y respuestas de sintéticos (Bisbee et al., 2024). Por un lado, encontramos que los propios cambios de un modelo pueden generar nuevas versiones y adaptaciones de las respuestas. Por otro lado, la evolución y cambio de las preferencias humanas genera también una variabilidad extra. Para solucionar o dar respuesta a esta situación se propone realizar un estudio periódico de manera longitudinal para comparar muestras sintéticas con humanas, para poder integrar esa variabilidad comentada en el propio modelo, teniendo en cuenta las dos fuentes distintas de cambio. Es importante en este tipo de validaciones analizar las distribuciones, heterogeneidad y estabilidad de las respuestas.

Así pues, tanto la investigación como el propio uso de los participantes sintéticos apuntan hacia una validación de carácter continuo, que sea tanto ampliamente humana como ampliamente temporal. Cubrir estos dos frentes permite que los participantes sintéticos sean una herramienta de aceleración del estudio del comportamiento humano en distintos ámbitos.

Bibliografía

- Agnew, W., Bergman, A.S., Chien, J., Díaz, M., El-Sayed, S., Pittman, J., Mohamed, S. and McKee, K.R. (2024) 'The illusion of artificial inclusion', in *Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems*. New York: ACM, Article 286, pp. 1–12. Available at: https://doi.org/10.1145/3613904.3642703.
- Aher, G.V., Arriaga, R.I. and Kalai, A.T. (2023) 'Using large language models to simulate multiple humans and replicate human subject studies', in *Proceedings of the 40th International Conference on Machine Learning*. PMLR, 202, pp. 337–371. Available at: https://proceedings.mlr.press/v202/aher23a.html.
- Amini, A. (2025) 'Survey transfer learning: recycling data with silicon responses', *arXiv preprint*, arXiv:2501.06577. Available at: https://doi.org/10.48550/arXiv.2501.06577.
- Arora, N., Chakraborty, I. and Nishimura, Y. (2025) 'AI–human hybrids for marketing research: leveraging large language models (LLMs) as collaborators', *Journal of Marketing*, 89(2), pp. 43–70. Available at: https://doi.org/10.1177/00222429241276529.
- Baker, R., Blumberg, S.J., Brick, J.M., Couper, M.P., Courtright, M., Dennis, J.M., Dillman, D., Frankel, M.R., Garland, P., Groves, R.M., Kennedy, C., Krosnick, J., Lavrakas, P.J., Lee, S., Link, M., Piekarski, L., Rao, K., Thomas, R.K. and Zahs, D. (2010) 'Research synthesis: AAPOR report on online panels', *Public Opinion Quarterly*, 74(4), pp. 711–781. Available at: https://doi.org/10.1093/poq/nfq048.
- Bandura, A. (1977) 'Self-efficacy: toward a unifying theory of behavioral change', *Psychological Review*, 84(2), pp. 191–215. Available at: https://doi.org/10.1037/0033-295X.84.2.191.
- Bisbee, J., Clinton, J.D., Dorff, C., Kenkel, B. and Larson, J.M. (2024) 'Synthetic replacements for human survey data? The perils of large language models', *Political Analysis*, 32(4), pp. 401–416. Available at: https://doi.org/10.1017/pan.2024.5.
- Cheung, V., Maier, M. and Lieder, F. (2025) 'Large language models show amplified cognitive biases in moral decision-making', *Proceedings of the National Academy of Sciences*, 122(25), e2412015122. Available at: https://doi.org/10.1073/pnas.2412015122.
- Cui, Z., Li, N. and Zhou, H. (2025) 'A large-scale replication of scenario-based experiments in psychology and management using large language models', *Nature Computational Science*, 5(8), pp. 627–634. Available at: https://doi.org/10.1038/s43588-025-00840-7.
- Dillion, D., Tandon, N., Gu, Y. and Gray, K. (2023) 'Can AI language models replace human participants?', *Trends in Cognitive Sciences*, 27(7), pp. 597–600. Available at: https://doi.org/10.1016/j.tics.2023.04.008.
- Doudkin, A.A., Pataranutaporn, P. and Maes, P. (2025) 'From synthetic to human: the gap between AI-predicted and actual pro-environmental behavior change after chatbot persuasion', in *Proceedings of the 7th ACM International Conference on Conversational User Interfaces (CUI 2025)*. New York: ACM, Article 71, pp. 1–18. Available at: https://doi.org/10.1145/3719160.3736610.
- Gao, Y., Lee, D., Burtch, G. and Fazelpour, S. (2025) *Take caution in using LLMs as human surrogates: Scylla ex machina*. Marketing Science Institute Working Paper Series, Report No. 25-100.
- Hofstede, G., Hofstede, G.J. and Minkov, M. (2010) *Cultures and organizations: software of the mind: intercultural cooperation and its importance for survival*. 3rd edn. New York: McGraw-Hill.
- Ibrahim, L., Hafner, F.S. and Rocher, L. (2026) 'Training language models to be warm can reduce accuracy and increase sycophancy', *Nature*, 652(8112), pp. 1159–1165. Available at: https://doi.org/10.1038/s41586-026-10410-0.
- Kahneman, D. (2011) *Thinking, fast and slow*. New York: Farrar, Straus and Giroux.
- Kahneman, D. and Tversky, A. (1979) 'Prospect theory: an analysis of decision under risk', *Econometrica*, 47(2), pp. 263–292. Available at: https://doi.org/10.2307/1914185.
- Lin, Z. (2025) 'Six fallacies in substituting large language models for human participants', *Advances in Methods and Practices in Psychological Science*, 8(3), pp. 1–19. Available at: https://doi.org/10.1177/25152459251357566.
- Mitchell, M. and Krakauer, D.C. (2023) 'The debate over understanding in AI's large language models', *Proceedings of the National Academy of Sciences*, 120(13), e2215907120. Available at: https://doi.org/10.1073/pnas.2215907120.
- MRS Delphi Group (2024) *Using synthetic participants for market research*. London: Market Research Society. Available at: https://www.mrs.org.uk/pdf/MRS_Delphi_synthetic.pdf.

- Park, J.S., O'Brien, J.C., Cai, C.J., Morris, M.R., Liang, P. and Bernstein, M.S. (2023) 'Generative agents: interactive simulacra of human behavior', in *Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology*. New York: ACM, pp. 1–22. Available at: https://doi.org/10.1145/3586183.3606763.
- Qu, Y. and Wang, J. (2024) 'Performance and biases of large language models in public opinion simulation', *Humanities and Social Sciences Communications*, 11, Article 1095. Available at: https://doi.org/10.1057/s41599-024-03609-x.
- Sarstedt, M., Adler, S.J., Rau, L. and Schmitt, B. (2024) 'Using large language models to generate silicon samples in consumer and marketing research: challenges, opportunities, and guidelines', *Psychology & Marketing*, 41(6), pp. 1254–1270. Available at: https://doi.org/10.1002/mar.21982.
- Shanahan, M., McDonell, K. and Reynolds, L. (2023) 'Role play with large language models', *Nature*, 623(7987), pp. 493–498. Available at: https://doi.org/10.1038/s41586-023-06647-8.
- Shrestha, P., Krpan, D., Koaik, F., Schnider, R., Sayess, D. and Binbaz, M.S. (2025) 'Beyond WEIRD: can synthetic survey participants substitute for humans in global policy research?', *Behavioral Science & Policy*, 10(2), pp. 26–45. Available at: https://doi.org/10.1177/23794607241311793.
- Simon, H.A. (1955) 'A behavioral model of rational choice', *The Quarterly Journal of Economics*, 69(1), pp. 99–118. Available at: https://doi.org/10.2307/1884852.
- Stamatogiannakis, A., Ghodsinia, A., Etminanrad, S., Gonçalves, D. and Santos, D. (2025) 'How human is the machine? Evidence from 66,000 conversations with large language models', *arXiv preprint*, arXiv:2510.07321. Available at: https://doi.org/10.48550/arXiv.2510.07321.
- Thaler, R.H. (2015) *Misbehaving: the making of behavioral economics*. New York: W.W. Norton & Company.
- Tjuatja, L., Chen, V., Wu, T., Talwalkar, A. and Neubig, G. (2024) 'Do LLMs exhibit human-like response biases? A case study in survey design', *Transactions of the Association for Computational Linguistics*, 12, pp. 1011–1026.
- Todd, P.M. and Gigerenzer, G. (2007) 'Environments that make us smart: ecological rationality', *Current Directions in Psychological Science*, 16(3), pp. 167–171. Available at: https://doi.org/10.1111/j.1467-8721.2007.00497.x.
- Tversky, A. and Kahneman, D. (1974) 'Judgment under uncertainty: heuristics and biases', *Science*, 185(4157), pp. 1124–1131. Available at: https://doi.org/10.1126/science.185.4157.1124.
- Ustiyanovych, J. and Krpan, D. (2025) *The potential of synthetic twin agents for personalized behavioural interventions at scale*. Preprint. PsyArXiv. Available at: https://doi.org/10.31234/osf.io/vs2mk_v3.
- Vanberg, V.J. (2004) 'The rationality postulate in economics: its ambiguity, its deficiency and its evolutionary alternative', *Journal of Economic Methodology*, 11(1), pp. 1–29. Available at: https://doi.org/10.1080/1350178042000177987.
- Zhong, R., McDonald, D.W. and Hsieh, G. (2025) 'Synthetic heuristic evaluation: a comparison between AI- and human-powered usability evaluation', *arXiv preprint*, arXiv:2507.02306. Available at: https://doi.org/10.48550/arXiv.2507.02306.

Sobre los autores

Paola Schietekat es consultora senior de Economía Conductual en Neovantas, donde trabaja en proyectos relacionados con el desarrollo de modelos de inteligencia artificial para instituciones financieras. Paola tiene un B.A. en Relaciones Internacionales con minor en Social and Behavioral Sciences de la American University of Kuwait y un MPP de la Universidad de Oxford.

Olympia Arango es consultora de Economía Conductual en Neovantas, donde trabaja para aplicar behavioral insights al diseño de estrategias que permitan comprender mejor la toma de decisiones, impulsar cambios de comportamiento y generar impacto en el sector privado y público. Es economista por la Universitat Pompeu Fabra y cuenta con dos másteres: uno de investigación en Economía y Psicología por la Paris School of Economics y otro en Ciencias del Comportamiento e Inteligencia Artificial por la UNIR.

Otras publicaciones

Oct 2026	DT	Más allá del crecimiento y el decrecimiento: Redescubrir el propósito de la economía en el siglo XXI	Diego Isabel La Moneda
Set 2026	NT	Identificación de los factores determinantes del precio del Eurostoxx 50 mediante Análisis de Componentes Principales (PCA) y Regresión sobre Componentes Principales (PCR), 2005-2025	Carles Ruiz Rovira
Jun 2026	DT	La huella de carbono de la investigación en economía en la era de la IA generativa	Andres Alonso-Robisco
Jun 2026	DT	Ahorro y riqueza intergeneracional ante el reto demográfico	Fernando Rojas, Pablo Victoria, Diego Romero, Francisco del Olmo García
May 2026	DT	Aplicación de sistemas multiagente de IA	Júlia Pou, Eric Garcia, Miquel Heredia, Carlos Salinas, Gerard Alba
May 2026	DT	Comportamiento racional en los mercados financieros	Antonio Hormigos
Feb 2026	DT	Stablecoins en Tesorería: Usos, Ventajas y Riesgos	Carlos de Fuenmayor
Dic 2025	DT	Fondos de Inversión Alternativa: Private Equity y Deuda Privada	Josep Martínez Pascual
Oct 2025	DT	La Energía Nuclear en el Marco de la Transición Energética	Antonio González Jiménez
Set 2025	DT	Artificial Intelligence in economics and finance: an AI-driven literature review	Andres Alonso-Robisco
Jun 2025	NT	The Crypto space under the new trump administration	Sergi Barberán
Abr 2025	DT	Método Sistemático para encontrar empresas de calidad	Ferran Carreras Lavila
Mar 2025	DT	Escenarios de la inversión de impacto ante el inversor particular	Andrea González G.Vega
Feb 2025	NT	Los informes Letta y Draghi: Mismas recetas…¿distintos resultados? Una mirada crítica	Pablo Agnese
Ene 2025	DT	How similar is the Chinese economy to that of Japan after the bubble burst?	Alicia García Herrero
Nov 2024	DT	Resolving sovereign in the era of geopolitical tensions	Sergi Lanau
Oct 2024	DT	Shadow Banking: current Headaches, Old Problems?	David Ramos Muñoz
Set 2024	DT	Situación actual de los NFTs y del Metaverso	Joaquim Matinero Tor
Set 2024	NT	La macroeconomía argentina y los primeros días del experimento anarcocapitalista del presidente Milei	Alejandro D. Jacobo