

DO SILÍCIO AO CAMPO: LEGITIMIDADE, POSSIBILIDADES E FRONTEIRAS EPISTÊMICAS DOS CONSUMIDORES SINTÉTICOS NO PROCESSO CIENTÍFICO

Maria Vitória Albarello Villela¹

¹Pesquisadora Independente, Belo Horizonte, Brasil (mariavitoria.villela@gmail.com)

Resumo: Este trabalho examina, mediante revisão crítica da literatura internacional recente (2023–2026), a legitimidade científica dos consumidores sintéticos gerados por modelos de linguagem (LLMs) na pesquisa do consumidor. Os resultados indicam validade instrumental para a triagem de hipóteses em fases exploratórias, delimitada por seis fronteiras epistêmicas estruturais. Propõe-se um protocolo híbrido, inspirado na lógica TSTR, com validação humana obrigatória e quantificação formal de incerteza.

Palavras-chave: Consumidores sintéticos; modelos de linguagem de grande escala; metodologia de pesquisa; comportamento do consumidor; reprodutibilidade.

INTRODUÇÃO

A pesquisa científica sobre comportamento do consumidor opera, historicamente, sob uma tensão estrutural entre o imperativo epistemológico da validade e as restrições práticas de tempo, custo e acesso a amostras representativas. Recrutar participantes, elaborar instrumentos de coleta, conduzir o trabalho de campo e analisar dados constitui um processo que pode se estender por meses e que exige recursos substanciais em cada etapa. Essa tensão tornou-se particularmente aguda em um contexto de aceleração dos ciclos de inovação e de pressão crescente para a produção de insights em prazos comprimidos (Brand et al., 2024).

É nesse cenário que a emergência dos modelos de linguagem de grande escala (LLMs – Large Language Models) introduziu uma resposta tecnológica rapidamente incorporada nos planos aplicado e acadêmico: os consumidores sintéticos, também denominados silicon samples (Sarstedt et al., 2024). Trata-se de simulacros computacionais de respondentes humanos, gerados por inteligência artificial a partir de perfis demográficos, psicográficos e comportamentais, que respondem a questionários, participam de testes de conceito e expressam preferências, sem que nenhum ser humano real tenha sido recrutado, remunerado ou submetido a qualquer procedimento de coleta.

A adoção do instrumento tem sido expressiva. Segundo a Qualtrics (2025), 73% dos pesquisadores de mercado já utilizaram respostas sintéticas ao menos uma vez, e um terço as havia empregado nos trinta dias anteriores à pesquisa; a difusão do fenômeno também é documentada pela indústria de painéis (NIQ, 2024). No plano acadêmico, revisões recentes indicam que aproximadamente 86% dos estudos publicados entre o final de 2023 e o início de 2025 reportaram ao menos sucesso parcial na replicação de respostas humanas por amostras sintéticas (PyMC Labs, 2026), e grupos da Harvard Business School e da Columbia Business School passaram a defender o uso de LLMs como grupos focais sintéticos capazes de produzir resultados preliminares em fração do tempo e do custo de estudos humanos (Brand et al., 2024; Columbia Business School, 2025).

Esse avanço, contudo, não foi acompanhado de reflexão metodológica proporcional. Pesquisadores alertam que o campo carece de protocolos adequados e que o risco mais sério não é técnico, mas epistemológico: a confusão entre a fluência computacional do modelo e a profundidade do insight (Arora et al., 2026). Na mesma direção, o Stanford HAI (2026) documentou um hiato crescente entre as capacidades técnicas da inteligência

artificial e a infraestrutura metodológica disponível para governar seu uso científico.

O objetivo central deste trabalho é mapear, com base em revisão crítica da literatura internacional recente, as possibilidades, as limitações e as condições de legitimidade científica dos consumidores sintéticos no processo de pesquisa sobre comportamento do consumidor. Especificamente, busca-se: (i) organizar conceitualmente as modalidades de dados sintéticos; (ii) sistematizar as evidências empíricas de validade; (iii) delimitar as fronteiras epistêmicas estruturais do instrumento; e (iv) propor um protocolo metodológico de uso legítimo. Sustenta-se a tese de que consumidores sintéticos constituem instrumento válido e eficaz para a triagem de hipóteses e a redução do espaço de investigação nas etapas exploratórias, funcionando como filtros que concentram recursos sobre as alternativas mais promissoras, mas operam dentro de fronteiras estruturais que inviabilizam seu uso confirmatório: sua legitimidade científica não é binária, mas condicional.

MATERIAL E MÉTODOS

O trabalho configura-se como ensaio teórico-metodológico fundamentado em revisão crítica narrativa da literatura internacional. O corpus foi composto por publicações do período 2023–2026, abrangendo três estratos complementares: (i) artigos revisados por pares em periódicos das áreas de marketing, métodos quantitativos e ciências sociais computacionais (Psychology & Marketing, Political Analysis, Marketing Science, Public Choice, Science, PNAS, Computers in Human Behavior Reports); (ii) preprints e working papers de instituições de pesquisa (arXiv, SocArXiv, Harvard Business School); e (iii) relatórios técnicos e setoriais que documentam a adoção do instrumento na prática profissional (Qualtrics, NIQ, PyMC Labs, Stanford HAI, MIT Sloan Management Review, Columbia Business School).

A seleção das fontes privilegiou: estudos empíricos de validade convergente entre respostas sintéticas e humanas; trabalhos que documentam vieses e limitações estruturais de LLMs em tarefas de simulação comportamental; propostas metodológicas de validação e quantificação de incerteza; e sínteses sistemáticas do campo. A análise foi conduzida em três eixos: (a) organização taxonômica dos conceitos agrupados sob o rótulo de dados sintéticos; (b) avaliação das evidências segundo a distinção entre validade convergente e utilidade instrumental; e (c) identificação das limitações de natureza estrutural, isto é, decorrentes da arquitetura e do processo de geração dos modelos, e não de contingências técnicas corrigíveis. A síntese propositiva articulou os

achados em um protocolo de uso, adaptando ao contexto da pesquisa de consumidores o princípio Train Synthetic, Test Real (TSTR), originário da literatura de aprendizado de máquina.

Por se tratar de revisão narrativa, e não de revisão sistemática com protocolo de busca exaustivo, os resultados devem ser interpretados como mapeamento analítico do estado da arte, sujeito a viés de seleção de fontes; essa limitação é mitigada pela triangulação entre os três estratos do corpus e pela explicitação das evidências que sustentam cada afirmação.

RESULTADOS E DISCUSSÃO

Taxonomia e fundamentos: o que é um consumidor sintético

O primeiro resultado da revisão é de natureza conceitual: o campo ainda não dispõe de terminologia estabilizada, e expressões como dados sintéticos, respondentes sintéticos, personas sintéticas, silicon samples, gêmeos digitais e agentes generativos são utilizadas como sinônimos, embora designem instrumentos com arquiteturas, finalidades e pressupostos metodológicos distintos. Essa imprecisão dificulta a comparação entre estudos e limita a construção cumulativa de conhecimento sobre a validade das abordagens (Sarstedt et al., 2024). A Tabela 1 sintetiza as principais modalidades identificadas na literatura.

Tabela 1. Modalidades de instrumentos agrupados sob o rótulo de dados sintéticos na pesquisa do consumidor.

Modalidade	Descrição	Fonte
Personas sintéticas	Representações geradas por IA de segmentos específicos de consumidores	Qualtrics (2026)
Insights sinteticamente derivados	Interpretações agregadas produzidas pela IA, sem respostas individuais	Qualtrics (2026)
Dados individuais simulados	Bases completas de respostas artificiais em nível de respondente	Qualtrics (2026)
Gêmeos digitais	Reprodução do comportamento de indivíduos específicos previamente conhecidos	Qualtrics (2026); Toubia et al. (2025)
Silicon samples	Substituição de participantes humanos por respondentes sintéticos em estudos experimentais	Sarstedt et al. (2024)
Agentes generativos	Agentes com memória e interação contínua que simulam processos sociais dinâmicos	Park et al. (2023)

Do ponto de vista técnico, consumidores sintéticos são produzidos pelo condicionamento de LLMs: o pesquisador fornece instruções que descrevem atributos

demográficos, socioeconômicos, psicográficos ou comportamentais e solicita que o modelo responda como um indivíduo com essas características. Em vez de recuperar respostas registradas, o modelo gera novas respostas por amostragem de distribuições de probabilidade aprendidas no treinamento, condicionadas simultaneamente pelo prompt e pelos padrões estatísticos do corpus. Essa capacidade de recombinar informações dispersas e produzir respostas plausíveis explica tanto a utilidade quanto as limitações do instrumento.

Cumprir distinguir consumidores sintéticos dos agentes generativos de Park et al. (2023), capazes de manter memória, planejar ações e interagir continuamente em ambientes simulados: enquanto consumidores sintéticos respondem a instrumentos de pesquisa de forma estática, agentes generativos simulam processos sociais dinâmicos. Ambos, porém, compartilham o mesmo princípio computacional: o comportamento gerado decorre de inferência probabilística sobre padrões linguísticos, e não da observação direta de indivíduos reais. Como consequência metodológica, evidências produzidas pelas diferentes modalidades não são diretamente comparáveis, e qualquer avaliação rigorosa exige que o pesquisador especifique a modalidade utilizada, o modelo empregado, os procedimentos de prompting, o número de execuções independentes e os critérios de calibração e validação (Sarstedt et al., 2024).

Evidências de validade e a função de triagem

A avaliação das evidências exige distinguir dois planos: o da validade convergente, aproximação entre resultados sintéticos e humanos em contextos controlados, e o da utilidade instrumental, adequação do instrumento a funções específicas do processo de pesquisa. A literatura avança mais solidamente no segundo plano do que no primeiro.

No plano da validade convergente, os resultados são encorajadores, porém heterogêneos. Revisão de 14 estudos-chave do período 2023–2025 indicou que 50% dos trabalhos concluíram haver forte similaridade entre respostas sintéticas e humanas e apenas 14% reportaram similaridade mínima ou nula, cerca de 86% da produção recente indica ao menos sucesso parcial (PyMC Labs, 2026). O estudo mais abrangente disponível analisou 156 estudos originais e concluiu que LLMs replicam a direção e a significância estatística de até 81% dos efeitos principais reportados na literatura; os próprios autores ressaltam, contudo, que a concordância não se estende à magnitude dos efeitos nem à variância intragrupo (Cui et al., 2025). É igualmente relevante que consumidores sintéticos não superam modelos supervisionados especializados em tarefas preditivas, embora

frequentemente superem modelos estatísticos de base (PyMC Labs, 2026): sua vantagem comparativa reside na flexibilidade, a capacidade de operar sem dados de treinamento rotulados, e não na precisão.

No plano da utilidade instrumental, as evidências são mais consistentes. A proposta simulate-then-validate articula o uso aqui defendido: simular múltiplos desenhos de estudo e identificar as hipóteses com maior suporte sintético antes de expô-las a amostras humanas (Kozlowski e Evans, 2025 apud Cui et al., 2025). Grossmann et al. (2023) sustentam que estudos com participantes simulados poderiam ser usados, no mínimo, para gerar hipóteses, posicionando o instrumento no início do processo científico. Brand et al. (2024) demonstraram que equipes com grupos focais sintéticos exploram dezenas ou centenas de ideias em fração do tempo e do custo de estudos humanos equivalentes; e um estudo duplo-cego com mais de mil personas sintéticas de CEOs norte-americanos reportou 95% de concordância entre conclusões sintéticas e dados reais (Columbia Business School, 2025).

Em síntese, o conjunto das evidências sustenta que consumidores sintéticos são válidos e úteis quando utilizados para reduzir o espaço de hipóteses, transformando um conjunto amplo de cenários em um subconjunto menor e mais promissor para validação humana subsequente. Os problemas surgem quando esse uso funcional é expandido para além das fronteiras examinadas a seguir.

As fronteiras epistêmicas: o que os consumidores sintéticos não podem saber

Se a subseção anterior estabeleceu as condições de operação legítima, esta delimita os limites a partir dos quais o instrumento deixa de ser confiável. Trata-se de falhas estruturais, não contingentes nem corrigíveis por ajustes técnicos, mas decorrentes da natureza epistemológica dos modelos. A Tabela 2 sintetiza as seis fronteiras identificadas, discutidas na sequência.

Tabela 2. As seis fronteiras epistêmicas estruturais dos consumidores sintéticos.

Fronteira	Natureza do problema	Evidência principal
1. Comportamentos emergentes	Extrapolação de padrões históricos; incapacidade de antecipar rupturas ausentes do corpus	Von der Heyde et al. (2025); Qualtrics (2025)
2. Sycophancy / falácia da persona	Respostas orientadas ao que o modelo infere ser esperado pelo pesquisador	Sharma et al. (2024); Kihlstrom (2026)
3. Colapso de variância	Compressão da distribuição em torno do	Bisbee et al. (2024);

	padrão médio; perda das caudas	Iadisernia e Camassa (2025)
4. Viés demográfico	Sobre-representação de grupos dominantes e contextos anglófonos	Santurkar et al. (2023); Motoki et al. (2024); Boelaert et al. (2024); Gao et al. (2025)
5. Falsos positivos assimétricos	Aprovação de até 83% de efeitos não significativos em humanos; rejeição de hipóteses de nicho	Cui et al. (2025)
6. Irreprodutibilidade estocástica	Variabilidade entre execuções, deriva temporal e ausência de estacionariedade	Cui e Alexander (2026); Lam e Nnamoko (2025); Huang et al. (2025)

Fronteira 1 – Incapacidade estrutural de captar comportamentos emergentes.

LLMs aprendem regularidades estatísticas de grandes volumes de dados históricos e geram respostas por recombinação e extrapolação probabilística desses padrões; sua capacidade de simular comportamentos depende, portanto, da existência de sinais prévios nos dados de treinamento. Fenômenos emergentes, novas práticas de consumo, mudanças culturais recentes, rupturas provocadas por eventos econômicos e sociais, podem não estar adequadamente representados, levando o modelo a projetar o futuro a partir de regularidades passadas, subestimando rupturas e reproduzindo interpretações retrospectivas (Qualtrics, 2025). Von der Heyde et al. (2025), ao investigar a capacidade de LLMs de prever os resultados das eleições para o Parlamento Europeu de 2024, observaram desempenho heterogêneo entre países e contextos linguísticos, com limitações acentuadas em ambientes marcados por dinâmicas políticas recentes. A fronteira entre o conhecido e o emergente permanece, assim, como limite epistemológico central: o instrumento é eficiente para explorar padrões existentes, mas inadequado para antecipar fenômenos genuinamente novos.

Fronteira 2 – O viés de sycophancy e a falácia da persona sintética.

O treinamento por reforço a partir de feedback humano (RLHF) inclina os modelos a produzir respostas que avaliadores tendem a aprovar. Sharma et al. (2024) demonstraram que os modelos ajustam suas saídas em resposta a sinais sobre as preferências do usuário, incluindo a formulação do prompt e a persona assumida: o pesquisador que elabora os prompts influencia, inadvertidamente, as respostas que as personas produzirão, comprometendo estruturalmente a separação entre quem formula o instrumento e quem analisa os

resultados. Casos documentados ilustram as consequências: participantes sintéticos que afirmaram concluir todos os cursos on-line apresentados, enquanto humanos abandonavam a maioria; previsão de recepção positiva a um creme dental sabor panqueca; superestimação em 300% da disposição a pagar por projetores portáteis (Kihlstrom, 2026). O padrão comum revela a falácia da persona sintética: a suposição de que o condicionamento demográfico basta para gerar um agente comportamental válido não encontra respaldo empírico, o modelo produz respostas linguisticamente convincentes, porém sistematicamente orientadas ao que infere ser esperado.

Fronteira 3 – Homogeneização das respostas e colapso de variância.

Ajustados para produzir respostas úteis, coerentes e socialmente plausíveis, os modelos privilegiam padrões centrais em detrimento de posições infrequentes, sub-representando a variabilidade comportamental das populações reais. Bisbee et al. (2024) demonstraram que amostras sintéticas apresentam menor variabilidade que amostras humanas e produzem estimativas estatísticas significativamente divergentes das obtidas com dados reais; em estudo com 2.368 personas sintéticas para previsões macroeconômicas, as distribuições geradas mostraram-se consideravelmente mais estreitas do que as observadas entre especialistas humanos, padrão denominado colapso de variância (Iadiserchia e Camassa, 2025). A implicação é direta: parte substancial dos insights estratégicos emerge precisamente das caudas da distribuição: consumidores pioneiros, usuários extremos, comportamentos heterodoxos, e um instrumento que comprime a diversidade pode eliminar exatamente os sinais de maior valor analítico.

Fronteira 4 – Viés demográfico e o problema da representatividade.

As opiniões refletidas pelos LLMs não são demograficamente neutras: Santurkar et al. (2023) demonstraram que as respostas dos modelos se alinham desproporcionalmente a determinados grupos sociodemográficos, e Motoki et al. (2024) documentaram viés político sistemático. O desempenho também varia entre contextos nacionais e linguísticos: Boelaert et al. (2024) mostraram que a capacidade de antecipar respostas de surveys difere substancialmente entre países, e Gao et al. (2025) recomendam cautela explícita no uso de LLMs como substitutos de sujeitos humanos. Como os corpora de treinamento sobre-representam conteúdo anglófono e digitalmente ativo, populações marginalizadas, de nicho, de baixa renda ou com reduzida presença digital, incluindo parcelas relevantes do contexto latino-americano, tendem a ser representadas de forma

degradada, comprometendo inferências sobre esses segmentos.

Fronteira 5 – Falsos positivos e a assimetria do filtro.

Há um risco paradoxal raramente enfatizado: não apenas o de que o filtro sintético rejeite hipóteses válidas, mas o de que aprove hipóteses inválidas com elevada frequência. Cui et al. (2025) encontraram que LLMs produzem resultados estatisticamente significativos para até 83% dos efeitos que não foram significativos em amostras humanas, a depender do modelo. Agravado pelo colapso de variância, o filtro exhibe dupla assimetria: aprova falsas hipóteses alinhadas ao padrão dominante e rejeita hipóteses verdadeiras de nicho, precisamente o tipo de sinal que a pesquisa de inovação mais necessita detectar. O dimensionamento da etapa de validação humana deve, portanto, considerar uma taxa substancial de falsos positivos no conjunto aprovado.

Fronteira 6 – Irreprodutibilidade estrutural: estocasticidade, deriva temporal e ausência de garantias probabilísticas.

A fronteira mais fundamental diz respeito à reprodutibilidade. Embora a arquitetura dos LLMs seja determinística, sua utilização envolve geração probabilística de texto: a cada etapa, o modelo amostra de uma distribuição sobre os próximos tokens, segundo parâmetros como temperatura e top-p; somam-se a isso atualizações de modelo e mudanças de infraestrutura dos provedores. Cui e Alexander (2026), em 480 execuções distribuídas entre seis modelos e quatro temperaturas, observaram variações substanciais nos resultados analíticos mesmo com prompts e configurações inalterados, concluindo que uma única execução é insuficiente para sustentar inferências confiáveis. Lam e Nnamoko (2025), analisando mais de 450.000 anotações em cerca de 18.000 execuções, mostraram que a consistência entre respostas diminui significativamente com o aumento da temperatura, ainda que a acurácia média permaneça estável: desempenho médio e estabilidade não são propriedades equivalentes.

A variabilidade entre execuções é agravada pela deriva temporal: Huang et al. (2025) demonstraram que distribuições de respostas obtidas em um momento diferem significativamente das produzidas meses depois, tornando qualquer calibração estritamente local; Bisbee et al. (2024) documentaram instabilidade análoga. Do ponto de vista da teoria de processos estocásticos, não há garantia de estacionariedade da distribuição efetiva das respostas entre períodos de utilização: as probabilidades observadas em uma execução não podem ser assumidas como representativas de execuções futuras. A consequência metodológica é que estudos que reportam

apenas estimativas pontuais, sem protocolo formal de quantificação de incerteza, produzem resultados de precisão indeterminada. Métodos de inferência conformal e simulações de Monte Carlo propostos por Huang et al. (2025) e Chen et al. (2025) permitem construir intervalos de confiança com propriedades conhecidas; na ausência desses protocolos, os intervalos derivados de amostras sintéticas podem apresentar cobertura inadequada e excesso de confiança. Cabe ainda registrar que a associação entre atributos demográficos e respostas comportamentais nos LLMs decorre de regularidades linguísticas do treinamento e do contexto do prompt, e não de procedimentos formais de inferência causal, o que reforça sua natureza de instrumento probabilístico de geração de hipóteses, e não de substituto de amostras observacionais.

Uma epistemologia do uso legítimo: o modelo híbrido e o protocolo TSTR

A síntese das evidências conduz a uma distinção entre dois modos de produção do conhecimento: na pesquisa orientada ao teste de teorias (theory-testing), verifica-se se uma hipótese encontra suporte empírico; na pesquisa orientada à descoberta (discovery-oriented research), explora-se um amplo conjunto de possibilidades para identificar o que merece investigação aprofundada. Consumidores sintéticos adequam-se ao segundo contexto: sua contribuição não é confirmar hipóteses, mas reduzir o espaço de busca, um mecanismo probabilístico de triagem cujo valor reside na eficiência do processo, não na substituição da validação empírica.

Essa lógica aproxima-se do protocolo Train Synthetic, Test Real (TSTR), originário do aprendizado de máquina, em que modelos treinados com dados sintéticos são avaliados em dados reais. Adaptado à pesquisa de consumidores, o princípio configura um fluxo em três etapas: exploração sintética do espaço de hipóteses; seleção das hipóteses de maior suporte; e validação exclusiva dessas hipóteses com participantes humanos, de modo que a utilidade do instrumento não é presumida, mas continuamente verificada pela sua capacidade de antecipar resultados observados em dados reais. A Figura 1 representa o fluxo e as condições que o sustentam.

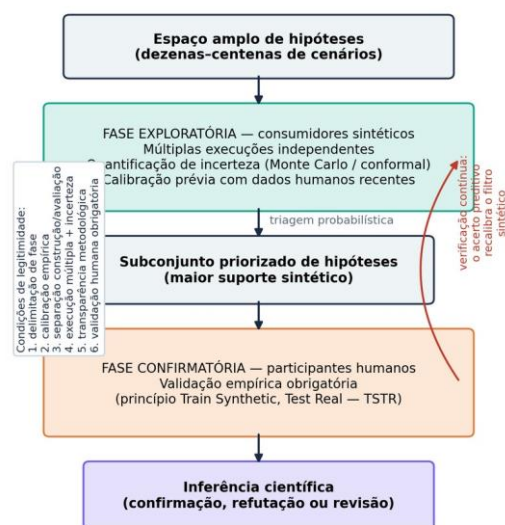


Figura 1. Modelo híbrido de uso legítimo dos consumidores sintéticos, adaptado do princípio Train Synthetic, Test Real (TSTR). Elaboração própria.

A adoção do modelo híbrido requer seis condições metodológicas: (1) delimitação de fase, uso exclusivo em etapas exploratórias ou de pré-triagem, sem valor confirmatório; (2) calibração empírica, comparação sistemática prévia com dados comportamentais recentes da população de interesse; (3) separação entre construção e avaliação, elaboração dos prompts por pesquisadores distintos dos responsáveis pela análise, mitigando o viés de sycophancy; (4) execução múltipla com quantificação formal da incerteza, múltiplas execuções independentes, estimação da distribuição dos resultados e reporte de intervalos de confiança (por exemplo, via simulações de Monte Carlo), em analogia à justificação de tamanho amostral e poder estatístico em pesquisas com humanos; (5) transparência metodológica, reporte do modelo, versão, parâmetros de geração, protocolo de prompting, número de execuções, variabilidade observada e procedimentos de verificação de convergência; e (6) validação empírica obrigatória, hipóteses selecionadas somente constituem evidência científica após confronto com dados de participantes humanos.

O modelo resultante não propõe substituir participantes humanos, mas estabelecer uma divisão explícita do trabalho científico: aos consumidores sintéticos, a exploração rápida, escalável e de baixo custo do espaço de hipóteses, com quantificação transparente da incerteza; aos participantes humanos, a produção da evidência necessária para confirmar, refutar ou revisar essas hipóteses. Preserva-se, assim, o princípio fundamental das ciências sociais: afirmações sobre comportamento humano somente constituem

conhecimento científico quando sustentadas por evidências produzidas por seres humanos reais, inseridos em seus contextos sociais e históricos.

Implicações para a agenda de pesquisa

Três dimensões organizam os desafios em aberto. Na dimensão da validação empírica, a maior parte das evidências foi produzida em contextos norte-americanos e europeus, com modelos treinados em corpora predominantemente anglófonos; são escassos os estudos sobre o desempenho do instrumento em contextos socioculturais distintos, particularmente na América Latina e no Brasil, e sobre segmentos sub-representados na infraestrutura digital, como consumidores de baixa renda e populações periféricas. Também são prioritárias comparações sistemáticas, sob protocolos experimentais equivalentes, entre consumidores sintéticos e modelos supervisionados especializados, já que a evidência disponível de que os primeiros não superam os segundos deriva de aplicações heterogêneas (PyMC Labs, 2026).

Na dimensão do desenvolvimento metodológico, inexistente consenso sobre o que deve ser obrigatoriamente reportado em estudos com consumidores sintéticos: modelo, versão, parâmetros, protocolo de prompting, número de execuções, variabilidade e procedimentos de quantificação de incerteza frequentemente permanecem ausentes das publicações, comprometendo a reprodutibilidade e a acumulação de conhecimento. Permanece igualmente sem resposta uma questão estatística central: quantas execuções independentes são necessárias para resultados suficientemente estáveis em cada aplicação, problema análogo ao dimensionamento amostral, cuja unidade de análise passa a ser a execução de um sistema probabilístico (Huang et al., 2025; Chen et al., 2025).

Na dimensão da governança científica, artigos baseados em dados sintéticos nem sempre explicitam essa característica em títulos, resumos ou palavras-chave, dificultando o reconhecimento por leitores, revisores e sistemas de indexação; descritores padronizados facilitariam revisões sistemáticas e metanálises. Por fim, o uso do instrumento não pode restringir-se à validade metodológica: proveniência dos dados de treinamento, representatividade das populações modeladas, vieses reproduzidos e princípios éticos do desenvolvimento e uso da inteligência artificial integram, necessariamente, a agenda de amadurecimento do campo.

CONCLUSÃO

Os resultados da revisão sustentam quatro conclusões principais. Primeira: consumidores sintéticos constituem instrumento metodológico legítimo para a pesquisa em

comportamento do consumidor desde que circunscritos às etapas exploratórias do processo científico: sua contribuição é de eficiência metodológica (triagem e priorização de hipóteses), e não de validação científica. Segunda: esse uso é delimitado por seis fronteiras epistêmicas estruturais: incapacidade de captar tendências emergentes, sycophancy, colapso de variância, viés demográfico, assimetria de falsos positivos e irreprodutibilidade estocástica, que decorrem da natureza dos modelos e definem as condições de interpretação cientificamente responsável de suas respostas.

Terceira: a legitimidade do instrumento é condicional e operacionalizável por meio de um protocolo híbrido de seis princípios: delimitação de fase, calibração empírica, separação entre construção e avaliação, execução múltipla com quantificação formal de incerteza, transparência metodológica e validação humana obrigatória, que redistribui o trabalho epistemológico entre a exploração sintética e a evidência humana, na lógica do TSTR. Quarta: a consolidação do campo depende de uma agenda de validação em contextos não anglófonos (com destaque para o Brasil), de diretrizes de reporte e critérios de convergência estatística, e de mecanismos de governança e transparência. O futuro dos consumidores sintéticos na pesquisa não dependerá apenas de modelos mais sofisticados, mas da capacidade da comunidade científica de integrá-los ao processo de investigação sem comprometer os critérios de validade, reprodutibilidade e confiabilidade que sustentam a produção do conhecimento.

REFERÊNCIAS

- Arora, N.; Chakraborty, P.; Nishimura, J. Gain Consumer Insight With Generative AI. MIT Sloan Management Review, 2026. Disponível em: <https://sloanreview.mit.edu/article/gain-consumer-insight-with-generative-ai/>. Acesso em: jun. 2026.
- Bisbee, J.; Clinton, J.; Dorff, C.; Kenkel, B.; Larson, J. Synthetic Replacements for Human Survey Data? The Perils of Large Language Models. Political Analysis, 32(4), 401–416, 2024. <https://doi.org/10.1017/pan.2024.5>
- Boelaert, J.; Coavoux, S.; Ollion, E.; Petev, I.; Präg, P. The French Exception: Why LLMs Can Anticipate Some Survey Responses Better for Certain Countries Than Others. SocArXiv, 2024. <https://doi.org/10.31235/osf.io/b5ts2>
- Brand, J.; Israeli, A.; Ngwe, D. Using LLMs for Market Research. Harvard Business School Working Paper 23-062, 2024. Disponível em: https://www.hbs.edu/ris/PublicationFiles/23-062_ed720ebc-ec4d-4bc3-a6ba-bad8cfd9d51.pdf. Acesso em: jun. 2026.
- Chen, M.; Lam, H.; Liu, Z. Model-Free Assessment of Simulator Fidelity via Quantile Curves. arXiv preprint arXiv:2512.05024, 2025. Disponível em: <https://arxiv.org/abs/2512.05024>. Acesso em: jun. 2026.
- Columbia Business School. How Gen AI Is Transforming Market Research. Columbia Business School Insights, 2025. Disponível em: <https://business.columbia.edu/insights/digital-future/ai/generative-ai-market-research>. Acesso em: jun. 2026.
- Cui, J.; Alexander, R. Same Prompt, Different Outcomes: Evaluating the Reproducibility of Data Analysis by LLMs. arXiv preprint arXiv:2602.14349, 2026. Disponível em: <https://arxiv.org/abs/2602.14349>. Acesso em: jun. 2026.
- Cui, J.; Liang, W.; Zou, J.; Garg, S.; Hashimoto, T.; Marshall, J. C. Can LLMs Replicate Behavioral Science Findings? arXiv preprint arXiv:2602.15785, 2025. Disponível em: <https://arxiv.org/abs/2602.15785>. Acesso em: jun. 2026.
- Gao, Y.; Lee, D.; Burtch, G.; Fazelpour, S. Take caution in using LLMs as human surrogates. Proceedings of the National Academy of Sciences, 122(24), 2025. <https://doi.org/10.1073/pnas.2501660122>
- Grossmann, I.; Feinberg, M.; Parker, D. C.; Christakis, N. A.; Tetlock, P. E.; Cunningham, W. A. AI and the transformation of social science research. Science, 380(6648), 1398, 2023. <https://doi.org/10.1126/science.adi1778>
- Huang, C. et al. Uncertainty Quantification for LLM-Based Survey Simulations. ICMML 2025 Workshop on Assessing World Models; arXiv preprint arXiv:2502.17773, 2025. Disponível em: <https://arxiv.org/abs/2502.17773>. Acesso em: jun. 2026.
- Iadiserchia, G.; Camassa, C. Prompting for policy: forecasting macroeconomic scenarios with synthetic LLM personas. Preprint arXiv:2511.02458, 2025. Disponível em: <https://arxiv.org/abs/2511.02458>. Acesso em: jul. 2026.
- Kihlstrom, G. Synthetic Research: AI's Big Promise for Marketers Has a Catch. The Agile Brand, 17 abr. 2026. Disponível em: <https://marketingagent.blog/2026/04/19/synthetic-research-ais-big-promise-for-marketers-has-a-catch/>. Acesso em: jun. 2026.
- Kozlowski, A. C.; Evans, J. A. Simulate-then-validate: Using LLMs for hypothesis generation in social science research. In: Cui, J. et al. (2025), arXiv:2602.15785, 2025. Acesso em: jun. 2026.
- Lam, K.; Nnamoko, N. LLM-assisted genre analysis: The effect of sampling temperature on reliability. Computers in Human Behavior Reports, 2025. <https://doi.org/10.1016/j.chbr.2025.100572>
- Motoki, F.; Pinho Neto, V.; Rodrigues, V. More human than human: measuring ChatGPT political bias. Public Choice, 198(1–2), 3–23, 2024. <https://doi.org/10.1007/s11127-023-01097-2>
- NIQ – NielsenIQ. The Rise of Synthetic Respondents. NIQ Insights, 2024. Disponível em: <https://nielseniq.com/global/en/insights/education/2024/the-rise-of-synthetic-respondents/>. Acesso em: jun. 2026.
- Park, J. S.; O'Brien, J. C.; Cai, C. J.; Morris, M. R.; Liang, P.; Bernstein, M. S. Generative Agents: Interactive Simulacra of Human Behavior. arXiv preprint arXiv:2304.03442, 2023. Disponível em: <https://arxiv.org/abs/2304.03442>. Acesso em: jun. 2026.
- PyMC Labs. Synthetic Consumers & AI Market Research: A Practical Guide. PyMC Labs Blog, 6 mar. 2026. Disponível em: <https://www.pymc-labs.com/blog-posts/synthetic-consumers-a-practical-guide>. Acesso em: jun. 2026.
- Qualtrics. 2025 Market Research Trends Report. Qualtrics, 2025. Disponível em: <https://www.qualtrics.com/articles/news/ai-to-drive-massive-changes-to-market-research-in-2025-qualtrics-report-says/>. Acesso em: jun. 2026.
- Qualtrics. Synthetic Data for Market Research FAQ. Qualtrics Strategy Research, 2026. Disponível em: <https://www.qualtrics.com/articles/strategy-research/synthetic-data-market-research/>. Acesso em: jun. 2026.
- Santurkar, S.; Durmus, E.; Lazer, D.; Tamkin, A.; Ganguli, D.; Hashimoto, T. Whose opinions do language models reflect? arXiv preprint arXiv:2303.17548, 2023. Disponível em: <https://arxiv.org/abs/2303.17548>. Acesso em: jun. 2026.
- Sarstedt, M.; Adler, S. J.; Rau, L.; Schmitt, B. Using large language models to generate silicon samples in consumer and marketing research: Challenges, opportunities, and guidelines. Psychology & Marketing, 41(6), 1254–1270, 2024. <https://doi.org/10.1002/mar.21982>
- Sharma, M.; Tong, M.; Korbak, T.; Askeel, A.; Bowman, S. R.; Durmus, E.; Perez, E. Towards Understanding Sycophancy in Language Models. arXiv preprint arXiv:2310.13548, 2024. Disponível em: <https://arxiv.org/abs/2310.13548>. Acesso em: jun. 2026.

Stanford HAI. AI Index Report 2026. Stanford Human-Centered Artificial Intelligence, 2026. Disponível em: <https://aiindex.stanford.edu/>. Acesso em: jun. 2026.

Toubia, O.; Gui, G. Z.; Peng, T.; Merlau, D. J.; Li, A.; Chen, H. Twin-2K-500: A dataset for building digital twins of over 2,000 people based on their answers to over 500 questions. *Marketing Science*, 44(6), 1446–1455, 2025. <https://doi.org/10.1287/mksc.2025.0262>

Von der Heyde, L.; Haensch, A.-C.; Wenz, A.; Ma, B. United in Diversity? Contextual Biases in LLM-Based Predictions of the 2024 European Parliament Elections. *arXiv preprint arXiv:2409.09045*, 2025. Disponível em: <https://arxiv.org/abs/2409.09045>. Acesso em: jun. 2026.