Jurnal Ekonomi, Teknologi dan Bisnis (JETBIS)
Volume 5, Number 10 October 2026, pp. 606-633
e-ISSN 2962-9330
https://doi.org/10.57185/jetbis.v5i10.357

Analisis Keberhasilan Sistem Informasi Berbasis Generative AI melalui Kualitas Informasi, Transparansi Algoritma, dan Kepercayaan Pengguna

Lanny Suryani Rohimah[1*], Mar'atus Solikhah[2]
Universitas Garut, Indonesia[1]
STMIK LIKMI, Bandung, Indonesia[2]
*e-mail:, lanny@uniga.ac.id

Keywords:
generative artificial intelligence; information systems success; information quality; algorithmic transparency; user trust; DeLone and McLean model

This is an open access article under the CC BY-SA license.

Copyright © 2026 by Author. Published by Al-Makki Publisher

Abstract

Background: *The development of Generative Artificial Intelligence (GenAI) has transformed the provision and utilization of information through interactive and adaptive information systems. However, issues such as the potential for misinformation ("hallucinations"), limited algorithmic transparency, and uncertainty regarding user trust pose challenges to the successful implementation of these systems. By August 2024, 39.4% of United States adults aged 18 to 64 had used GenAI, while a benchmark study found hallucinated content in 19.5% of sampled ChatGPT responses.*
Objective: *This study examines the effects of information quality, algorithmic transparency, and user trust on GenAI based information system success and demonstrates a replicable evaluation protocol.*
Methods: *This methodological simulation study develops a DeLone and McLean based conceptual model and a cross sectional survey protocol for adult GenAI users in Indonesia. As field data were unavailable, 200 synthetic cases on a five point Likert scale were generated from prespecified population parameters and analyzed using partial least squares structural equation modeling (PLS-SEM) with 5,000 bootstrap subsamples and PLSpredict.*
Results: *On the synthetic data, information quality ($\beta = 0.322$; $p < 0.001$) and user trust ($\beta = 0.384$; $p < 0.001$) were significantly and positively related to information system success, whereas algorithmic transparency was not significant ($\beta = 0.124$; $p = 0.056$). The model explained 48.8% of the variance ($R^2 = 0.488$) with high predictive power on holdout samples.*
Conclusion: *These estimates illustrate the procedure, not properties of the GenAI user population; the model requires testing with real respondent data before substantive conclusions are drawn.*

Kata Kunci:
kecerdasan buatan generatif; keberhasilan sistem informasi; kualitas informasi; transparansi algoritma; kepercayaan pengguna; model DeLone dan McLean

Abstrak

Latar Belakang: Perkembangan Generative Artificial Intelligence (GenAI) telah membawa perubahan dalam penyediaan dan pemanfaatan informasi melalui sistem informasi yang interaktif dan adaptif. Namun, potensi kesalahan informasi (hallucination), keterbatasan transparansi algoritma, serta ketidakpastian kepercayaan pengguna menjadi tantangan dalam menentukan keberhasilan penerapannya. Hingga Agustus 2024, 39,4% orang dewasa usia 18 sampai 64 tahun di Amerika Serikat telah menggunakan GenAI, sementara uji benchmark menemukan konten halusinatif pada 19,5% sampel respons ChatGPT.
Tujuan: Penelitian ini bertujuan menganalisis pengaruh kualitas informasi, transparansi algoritma, dan kepercayaan pengguna terhadap keberhasilan sistem informasi berbasis Generative AI serta mendemonstrasikan protokol evaluasinya.

Metode: Penelitian ini merupakan studi metodologis berbasis simulasi yang mengembangkan model konseptual berdasarkan model DeLone dan McLean serta protokol survei cross sectional bagi pengguna GenAI dewasa di Indonesia. Karena data lapangan belum tersedia, data sintetis 200 kasus berskala Likert lima poin dibangkitkan dari parameter populasi yang ditetapkan sebelumnya, lalu dianalisis dengan Partial Least Squares Structural Equation Modeling (PLS-SEM), bootstrapping 5.000 subsampel, dan PLSpredict.
Hasil: Pada data sintetis, kualitas informasi ($\beta = 0{,}322$; $p < 0{,}001$) dan kepercayaan pengguna ($\beta = 0{,}384$; $p < 0{,}001$) berhubungan positif dan signifikan dengan keberhasilan sistem informasi, sedangkan transparansi algoritma tidak signifikan ($\beta = 0{,}124$; $p = 0{,}056$). Model menjelaskan 48,8% variasi keberhasilan sistem informasi ($R^2 = 0{,}488$) dan memiliki daya prediksi di luar sampel yang tinggi.
Kesimpulan: Angka tersebut mengilustrasikan prosedur analisis dan bukan estimasi empiris populasi pengguna GenAI. Model dan protokol ini perlu diuji dengan data responden riil sebelum simpulan substantif ditarik, terutama untuk memastikan peran transparansi algoritma.

PENDAHULUAN

Perkembangan teknologi informasi telah memasuki fase transformasi yang ditandai dengan semakin luasnya pemanfaatan Generative Artificial Intelligence (Generative AI) dalam mendukung aktivitas pengolahan informasi, pengambilan keputusan, komunikasi, dan penyelesaian berbagai pekerjaan berbasis pengetahuan. Generative AI merupakan teknologi kecerdasan buatan yang mampu menghasilkan konten baru, seperti teks, gambar, kode program, dan informasi lainnya berdasarkan pola yang dipelajari dari data pelatihan. Kehadiran teknologi ini telah mengubah paradigma sistem informasi konvensional yang sebelumnya berorientasi pada penyimpanan, pemrosesan, dan penyajian data menjadi sistem yang mampu menghasilkan informasi secara interaktif dan kontekstual. Perubahan tersebut menjadikan Generative AI sebagai bagian penting dalam evolusi sistem informasi modern, terutama karena kemampuannya meningkatkan efisiensi akses informasi dan mendukung interaksi manusia dengan teknologi. Survei representatif nasional di Amerika Serikat menunjukkan bahwa pada Agustus 2024 sebanyak 39,4% penduduk usia 18 sampai 64 tahun telah menggunakan Generative AI dan 28% pekerja memanfaatkannya untuk pekerjaan, dengan laju adopsi yang lebih cepat daripada komputer pribadi maupun internet pada fase awalnya (Bick et al., 2024). Adopsi yang cepat tersebut menggeser pertanyaan evaluatif dari apakah Generative AI digunakan menjadi apakah penggunaannya berhasil menghasilkan informasi yang bermutu dan bermanfaat, sehingga evaluasi keberhasilan sistem informasi berbasis Generative AI menjadi kebutuhan yang mendesak. Namun, keberhasilan penerapan sistem informasi tidak hanya ditentukan oleh kecanggihan teknologi, tetapi juga oleh kemampuan sistem dalam menyediakan informasi yang berkualitas, dapat dipertanggungjawabkan, serta mampu membangun kepercayaan penggunanya (DeLone & McLean, 2003; Dwivedi et al., 2023; Feuerriegel et al., 2024).

Meskipun Generative AI menawarkan berbagai kemudahan, pemanfaatannya dalam sistem informasi masih menghadapi sejumlah tantangan mendasar, khususnya berkaitan dengan akurasi informasi, transparansi mekanisme algoritma, dan kepercayaan pengguna terhadap hasil yang dihasilkan sistem. Salah satu permasalahan yang menjadi perhatian adalah fenomena AI hallucination, yaitu kondisi ketika sistem menghasilkan informasi yang tampak meyakinkan secara linguistik, tetapi tidak sesuai dengan fakta atau tidak memiliki dasar pembuktian yang memadai.

Kondisi tersebut dapat menimbulkan risiko kesalahan pemahaman, penyebaran informasi yang tidak valid, hingga pengambilan keputusan yang kurang tepat. Selain itu, karakteristik algoritma Generative AI yang kompleks dan sulit dijelaskan dapat menyebabkan pengguna tidak memahami bagaimana suatu informasi dihasilkan, sumber informasi yang digunakan, serta faktor yang memengaruhi keluaran sistem. Oleh karena itu, penelitian mengenai keberhasilan sistem informasi berbasis Generative AI menjadi semakin penting untuk memastikan bahwa pemanfaatan teknologi tidak hanya berorientasi pada kecepatan dan kemudahan, tetapi juga pada kualitas informasi, keterbukaan algoritma, dan kepercayaan yang proporsional dari pengguna (Li et al., 2023; Farquhar et al., 2024; Autio et al., 2024). Dalam konteks Indonesia, survei terhadap 508 partisipan perguruan tinggi menunjukkan bahwa kelengkapan, presisi, ketepatan waktu, kemudahan, dan format informasi berperan paling kuat dalam membentuk kepuasan pengguna terhadap informasi ChatGPT (Fu et al., 2024), sedangkan survei terhadap 195 responden perguruan tinggi di Nusa Tenggara Barat menempatkan kepercayaan sebagai prediktor terkuat intensi penggunaan Generative AI (Fitriyani et al., 2026). Berdasarkan kondisi tersebut, penelitian ini membatasi fokus evaluasi pada pengguna individu berusia minimal 18 tahun yang memakai platform Generative AI percakapan, seperti ChatGPT, Gemini, Copilot, dan Claude, untuk mencari, merangkum, dan menyusun informasi bagi keperluan belajar maupun bekerja. Keberhasilan sistem dinilai dari persepsi pengguna atas kepuasan, intensi penggunaan berkelanjutan, dan manfaat bersih yang diperoleh dari aktivitas tersebut.

Dalam perspektif keilmuan sistem informasi, keberhasilan suatu sistem dapat dianalisis menggunakan DeLone and McLean Information Systems Success Model. Model yang dikembangkan oleh DeLone dan McLean (1992) menjelaskan bahwa keberhasilan sistem informasi merupakan konstruk multidimensional yang mencakup kualitas sistem, kualitas informasi, penggunaan sistem, kepuasan pengguna, dampak individual, dan dampak organisasi. Model tersebut kemudian diperbarui pada tahun 2003 dengan memasukkan kualitas layanan serta mengintegrasikan dampak individual dan organisasi ke dalam dimensi net benefits. Berdasarkan kerangka tersebut, kualitas informasi menjadi salah satu elemen fundamental karena mencerminkan kemampuan sistem dalam menghasilkan informasi yang akurat, relevan, lengkap, mudah dipahami, dan tepat waktu. Dalam konteks Generative AI, kualitas informasi memiliki posisi yang semakin strategis karena keluaran sistem tidak selalu berasal dari proses pengambilan data yang bersifat deterministik, melainkan melalui mekanisme generatif yang memungkinkan munculnya informasi baru. Dengan demikian, evaluasi keberhasilan sistem informasi berbasis Generative AI memerlukan perhatian khusus terhadap kualitas informasi yang dihasilkan sebagai representasi nilai fungsional sistem bagi pengguna (DeLone & McLean, 1992; DeLone & McLean, 2003; Petter et al., 2008). Penelitian ini tidak memasukkan kualitas sistem dan kualitas layanan karena pada platform Generative AI komersial kedua dimensi tersebut relatif seragam bagi seluruh pengguna, yaitu antarmuka percakapan dan layanan daring yang distandardisasi penyedia, sehingga variasi penilaian pengguna lebih banyak ditentukan oleh mutu keluaran, keterjelasan proses, dan keyakinan terhadap sistem. Penggunaan aktual tidak dimodelkan terpisah karena pada layanan yang bersifat sukarela, intensi penggunaan berkelanjutan lebih informatif daripada frekuensi pemakaian, sedangkan dampak individual tercakup dalam manfaat bersih dan dampak organisasional berada di luar cakupan karena unit analisisnya adalah pengguna individu (DeLone & McLean, 2003; Petter et al., 2008). Dengan demikian, keberhasilan sistem informasi diperlakukan sebagai konstruk reflektif tingkat pertama

yang merepresentasikan evaluasi keseluruhan pengguna dan tercermin pada kepuasan, intensi penggunaan berkelanjutan, serta manfaat bersih. Pilihan parsimoni ini diakui sebagai keterbatasan karena dalam model aslinya ketiga dimensi tersebut merupakan konstruk berbeda yang saling memengaruhi (Marjanovic et al., 2024; Mijač, 2025).

Urgensi pengujian kualitas informasi dalam sistem berbasis Generative AI diperkuat oleh sejumlah temuan empiris mengenai potensi ketidakakuratan keluaran model kecerdasan buatan. Penelitian Li et al. (2023) melalui pengembangan HaluEval Benchmark menemukan bahwa sekitar 19,5% respons ChatGPT pada sampel benchmark mengandung informasi halusinatif atau tidak terverifikasi. Selanjutnya, Farquhar et al. (2024) dalam penelitian yang dipublikasikan pada jurnal Nature menjelaskan bahwa model bahasa besar dapat menghasilkan informasi keliru dengan tingkat keyakinan linguistik yang tinggi sehingga pengguna perlu memiliki mekanisme untuk mengidentifikasi ketidakpastian jawaban. Permasalahan tersebut juga menjadi perhatian National Institute of Standards and Technology (NIST) melalui publikasi Generative Artificial Intelligence Profile yang mengidentifikasi fenomena confabulation sebagai salah satu risiko utama Generative AI (Autio et al., 2024). Temuan tersebut memperlihatkan bahwa kemampuan sistem menghasilkan jawaban secara cepat dan komunikatif belum dapat dijadikan satu-satunya indikator keberhasilan, melainkan harus diimbangi dengan evaluasi terhadap validitas dan keandalan informasi yang disajikan (Li et al., 2023; Farquhar et al., 2024; Autio et al., 2024). Temuan benchmark tersebut relevan dengan indikator akurasi dan kelengkapan pada konstruk kualitas informasi dalam penelitian ini, tetapi tidak dapat digeneralisasi sebagai tingkat halusinasi yang dialami pengguna sehari-hari karena dihasilkan dari kueri uji, versi model, dan prosedur anotasi tertentu. Berdasarkan argumen tersebut, informasi yang akurat, relevan, lengkap, tepat waktu, dan mudah dipahami diharapkan meningkatkan kepuasan, intensi penggunaan berkelanjutan, dan manfaat bersih yang dirasakan pengguna, sehingga dirumuskan H1: kualitas informasi berpengaruh positif terhadap keberhasilan sistem informasi berbasis Generative AI.

Tabel 1. Data empiris pendukung penelitian

Peneliti/sumber	Data atau temuan	Relevansi penelitian
Ojo (2017)	Penelitian terhadap 442 responden di lima rumah sakit pendidikan Nigeria. Kualitas informasi berpengaruh terhadap penggunaan sistem ($\beta = 0,24$; $p < 0,001$) dan kepuasan pengguna ($\beta = 0,17$; $p < 0,001$).	Memperkuat hubungan kualitas informasi dengan keberhasilan sistem informasi.
Li et al. (2023)	Sekitar 19,5% respons ChatGPT pada sampel benchmark HaluEval mengandung informasi halusinatif atau tidak terverifikasi.	Menunjukkan pentingnya kualitas dan akurasi informasi.
Fitriyani et al. (2026)	Survei 195 responden di Nusa Tenggara Barat. Kepercayaan terhadap AI menjadi prediktor terkuat intensi perilaku ($\beta = 0,623$; $p < 0,001$). Transparansi algoritma berpengaruh terhadap persepsi kontrol ($\beta = 0,824$) dan	Mendukung relevansi transparansi algoritma dan kepercayaan pengguna pada Generative AI.

	kegunaan yang dirasakan (β = 0,562).	
Ning et al. (2024)	Studi pada konteks saran algoritmik menunjukkan bahwa transparansi meningkatkan pemanfaatan saran melalui mediasi trusting beliefs.	Mendukung keterkaitan transparansi algoritma dengan kepercayaan pengguna.

Sumber: Diolah dari Li et al. (2023), Ojo (2017), Fitriyani et al. (2026), dan Ning et al. (2024). Angka 19,5% merupakan hasil pengujian benchmark, bukan estimasi tingkat halusinasi seluruh pengguna atau seluruh model Generative AI.

Selain kualitas informasi, transparansi algoritma merupakan faktor penting yang perlu diperhatikan dalam mengevaluasi keberhasilan sistem informasi berbasis Generative AI. Transparansi algoritma mengacu pada sejauh mana pengguna memperoleh pemahaman mengenai cara kerja sistem, proses pengolahan informasi, dasar pembentukan keluaran, serta keterbatasan teknologi yang digunakan. Dalam konteks Generative AI, transparansi tidak selalu berarti membuka seluruh kode sumber atau parameter model, tetapi lebih menekankan pada kemampuan sistem dalam memberikan penjelasan yang dapat dipahami pengguna mengenai proses dan dasar informasi yang dihasilkan. Bitzer et al. (2023) menjelaskan bahwa transparansi algoritma merupakan konsep multidimensional yang memiliki keterkaitan dengan faktor anteseden dan konsekuensi dalam penggunaan sistem berbasis algoritma. Penelitian Grimmelikhuijsen (2023) juga menunjukkan bahwa aksesibilitas dan kemampuan menjelaskan proses algoritma dapat memengaruhi persepsi kepercayaan terhadap pengambilan keputusan otomatis. Sejalan dengan hal tersebut, eksperimen terhadap 491 partisipan oleh Liu (2021) menemukan bahwa transparansi melalui pemberian penjelasan dapat mengurangi ketidakpastian dan meningkatkan kepercayaan dalam interaksi manusia dengan AI. Dengan demikian, transparansi algoritma dapat dipandang sebagai mekanisme yang menjembatani kemampuan teknis sistem dengan pemahaman pengguna terhadap informasi yang dihasilkan (Bitzer et al., 2023; Grimmelikhuijsen, 2023; Liu, 2021). Penelitian ini membedakan transparansi algoritma dari explainability dan keterbukaan sumber informasi. Transparansi algoritma merujuk pada keterbukaan informasi tentang cara sistem bekerja dan batas kemampuannya, explainability merujuk pada kemampuan sistem memberikan alasan yang dapat dipahami atas keluaran tertentu, sedangkan keterbukaan sumber merujuk pada ketersediaan rujukan yang dapat ditelusuri (Rai, 2020; Shin, 2021). Karena kode, bobot, dan proses internal platform Generative AI komersial tidak dapat diakses pengguna, transparansi diukur sebagai transparansi yang dipersepsikan, yaitu penilaian pengguna atas informasi yang benar-benar ditampilkan sistem, seperti penjelasan cara menjawab, pernyataan keterbatasan, dan rujukan sumber (Ananny & Crawford, 2018; Grimmelikhuijsen, 2023). Definisi ini menjadi dasar indikator X2.1 sampai X2.5 pada kuesioner. Pengguna yang memahami dasar dan batas keluaran sistem lebih mampu menilai kelayakan informasi sehingga cenderung menilai sistem lebih bermanfaat dan memuaskan. Oleh karena itu, dirumuskan H2: transparansi algoritma berpengaruh positif terhadap keberhasilan sistem informasi berbasis Generative AI.

Faktor berikutnya yang memiliki peran strategis adalah kepercayaan pengguna (user trust), yaitu keyakinan pengguna bahwa sistem mampu memberikan informasi dan layanan yang dapat diandalkan, bekerja secara konsisten, serta tidak menimbulkan risiko yang tidak dapat diterima. Dalam penggunaan Generative AI, kepercayaan menjadi aspek penting karena pengguna sering kali

berinteraksi dengan sistem yang menghasilkan jawaban menyerupai komunikasi manusia, meskipun proses pembentukan informasi di baliknya tidak sepenuhnya dapat dipahami. Kepercayaan yang terlalu rendah dapat menyebabkan pengguna enggan memanfaatkan teknologi, sedangkan kepercayaan yang berlebihan dapat mendorong penerimaan informasi tanpa proses verifikasi yang memadai. Lockey et al. (2021) melalui tinjauan literatur mengidentifikasi transparansi dan explainability, akurasi dan reliabilitas, otomatisasi, antropomorfisme, serta ekstraksi data massal sebagai tantangan utama dalam membangun kepercayaan terhadap AI. Choung et al. (2023) juga menempatkan kepercayaan sebagai faktor penting dalam penerimaan teknologi kecerdasan buatan. Sementara itu, Kaplan et al. (2023) melalui kajian meta-analitik memperlihatkan pentingnya memahami faktor-faktor yang membentuk kepercayaan terhadap AI dalam interaksi manusia dan teknologi. Oleh karena itu, kepercayaan pengguna diposisikan sebagai variabel independen yang diuji secara paralel dengan kualitas informasi dan transparansi algoritma dalam menjelaskan persepsi keberhasilan sistem informasi berbasis Generative AI, sedangkan kemungkinan peran mediasinya diajukan sebagai agenda penelitian lanjutan (Lockey et al., 2021; Choung et al., 2023; Kaplan et al., 2023). Kepercayaan dalam penelitian ini diarahkan pada keyakinan terhadap kompetensi, reliabilitas, dan integritas sistem, dengan penekanan pada kepercayaan yang terkalibrasi, yaitu kepercayaan yang sebanding dengan kemampuan dan keterbatasan nyata Generative AI (Glikson & Woolley, 2020; Kaplan et al., 2023). Konstruk ini dibedakan dari kepuasan dan intensi penggunaan karena kepercayaan merupakan keyakinan tentang atribut sistem, sedangkan kepuasan dan intensi merupakan evaluasi serta kecenderungan perilaku setelah pengalaman penggunaan. Pengguna yang meyakini kompetensi dan keandalan sistem cenderung lebih puas, berniat terus menggunakan, dan merasakan manfaat yang lebih besar, sehingga dirumuskan H3: kepercayaan pengguna berpengaruh positif terhadap keberhasilan sistem informasi berbasis Generative AI.

Sejumlah penelitian terdahulu telah memberikan landasan empiris mengenai hubungan antara kualitas informasi, transparansi algoritma, kepercayaan pengguna, dan keberhasilan sistem informasi. Ojo (2017), melalui pengujian model DeLone dan McLean terhadap 442 pengguna sistem informasi rumah sakit di Nigeria, menemukan bahwa kualitas informasi berpengaruh signifikan terhadap penggunaan sistem dan kepuasan pengguna. Selanjutnya, penelitian Wang dan Ding (2024) menunjukkan bahwa pemberian penjelasan terhadap prediksi AI dapat meningkatkan akurasi keputusan pengguna dan kepercayaan dalam bentuk perilaku, meskipun tidak selalu meningkatkan persepsi kepercayaan yang dilaporkan secara subjektif. Penelitian yang lebih kontekstual dilakukan oleh Fitriyani et al. (2026) melalui survei terhadap 195 responden di perguruan tinggi wilayah Nusa Tenggara Barat. Penelitian tersebut mengintegrasikan kualitas antarmuka, transparansi algoritma, dan kepercayaan dalam menjelaskan adopsi Generative AI. Hasilnya menunjukkan bahwa kepercayaan terhadap AI merupakan prediktor terkuat intensi perilaku, sedangkan transparansi algoritma berpengaruh terhadap persepsi kontrol dan kegunaan yang dirasakan. Berbagai temuan tersebut memperlihatkan bahwa dimensi kualitas informasi, transparansi, dan kepercayaan telah memperoleh perhatian dalam penelitian sistem informasi maupun adopsi AI, tetapi masih terdapat ruang untuk mengembangkan kerangka evaluasi keberhasilan yang secara khusus mengintegrasikan ketiga dimensi tersebut (Ojo, 2017; Wang & Ding, 2024; Fitriyani et al., 2026). Studi yang menerapkan model DeLone dan McLean secara langsung pada ChatGPT juga mulai berkembang. Marjanovic et al. (2024) menguji model tersebut pada 2.897 mahasiswa STEM pengguna ChatGPT

dan menemukan empat dari lima hubungan yang dihipotesiskan didukung, sedangkan Mijač (2025) pada mahasiswa bisnis Generasi Z menemukan bahwa intensi penggunaan tidak berpengaruh signifikan terhadap manfaat bersih sehingga menyarankan adaptasi model untuk Generative AI. Jika dibandingkan, studi tersebut berbeda pada tiga aspek (Tabel 2). Pertama, variabel dependennya beragam, yaitu penggunaan dan kepuasan pada Ojo (2017), akurasi keputusan dan kepercayaan perilaku pada Wang dan Ding (2024), intensi perilaku pada Fitriyani et al. (2026), serta dimensi keberhasilan pada Marjanovic et al. (2024) dan Mijač (2025). Kedua, metodenya meliputi survei pada sistem informasi rumah sakit, eksperimen penjelasan AI, dan survei pengguna Generative AI. Ketiga, studi keberhasilan sistem informasi pada ChatGPT belum memasukkan transparansi algoritma dan kepercayaan, sementara studi adopsi yang memasukkan keduanya belum menggunakan keberhasilan sistem informasi sebagai variabel dependen. Celah inilah yang mengarahkan penyusunan model penelitian ini.

Tabel 2. Pemetaan Penelitian Terdahulu dan Posisi Penelitian Ini

Studi	Konteks dan sampel	Variabel dependen	Metode	Temuan kunci dan keterbatasan
Ojo (2017)	442 pengguna sistem informasi di lima rumah sakit pendidikan, Nigeria	Penggunaan dan kepuasan pengguna	Survei, SEM	Kualitas informasi berpengaruh pada penggunaan ($\beta = 0{,}24$) dan kepuasan ($\beta = 0{,}17$); bukan sistem AI
Wang dan Ding (2024)	Interaksi manusia dan AI dalam tugas keputusan	Akurasi keputusan dan kepercayaan	Eksperimen	Penjelasan AI meningkatkan akurasi dan kepercayaan perilaku, tetapi tidak selalu kepercayaan subjektif
Ning et al. (2024)	Saran algoritmik	Pemanfaatan saran algoritmik	Studi empiris	Transparansi bekerja melalui trusting beliefs; bukan konteks Generative AI
Fu et al. (2024)	508 partisipan perguruan tinggi di Indonesia, ChatGPT	Kepuasan informasi pengguna	Survei, PLS-SEM	Dimensi kualitas informasi menentukan kepuasan; tanpa transparansi dan kepercayaan
Marjanovic et al. (2024)	2.897 mahasiswa STEM pengguna ChatGPT	Dimensi keberhasilan DeLone dan McLean	Survei, SEM	Empat dari lima hubungan didukung; tanpa transparansi dan kepercayaan
Mijač (2025)	Mahasiswa bisnis Generasi Z pengguna ChatGPT	Dimensi keberhasilan DeLone dan McLean	Survei	Intensi penggunaan tidak signifikan terhadap manfaat bersih; tanpa transparansi dan kepercayaan
Fitriyani et al. (2026)	195 responden perguruan tinggi, Nusa Tenggara Barat	Intensi perilaku adopsi Generative AI	Survei, PLS-SEM	Kepercayaan prediktor terkuat ($\beta = 0{,}623$); variabel dependen adopsi, bukan keberhasilan sistem informasi
Penelitian ini	Protokol pengguna Generative AI dewasa di Indonesia; demonstrasi data sintetis (n = 200)	Keberhasilan sistem informasi	PLS-SEM, PLSpredict	Mengintegrasikan kualitas informasi, transparansi algoritma, dan kepercayaan sebagai prediktor keberhasilan

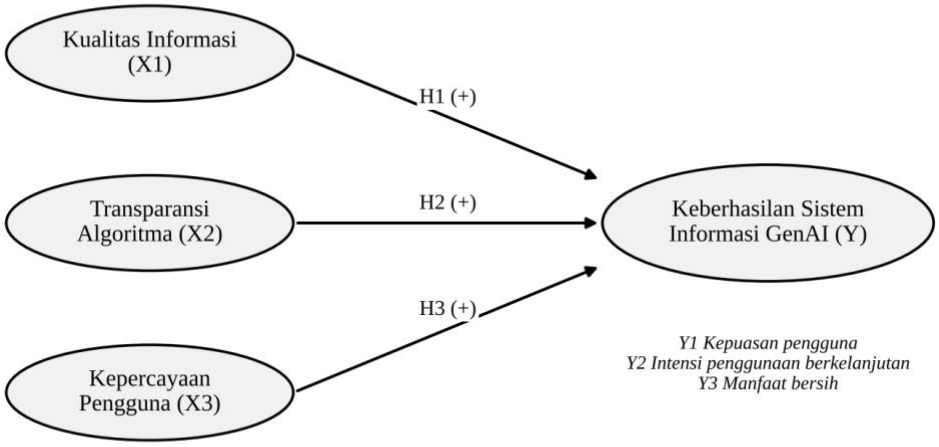
Sumber: Diolah dari studi yang dikutip pada tabel.

Meskipun penelitian mengenai keberhasilan sistem informasi dan penerimaan teknologi kecerdasan buatan telah berkembang, terdapat beberapa kesenjangan penelitian yang masih perlu dieksplorasi. Pertama, penelitian mengenai keberhasilan sistem informasi selama ini banyak menggunakan model DeLone dan McLean dengan menekankan kualitas sistem, kualitas informasi, kualitas layanan, penggunaan, kepuasan pengguna, dan manfaat bersih, sehingga karakteristik khusus Generative AI yang berkaitan dengan transparansi proses generatif belum sepenuhnya terakomodasi dalam kerangka evaluasi tersebut (DeLone & McLean, 2003; Petter et al., 2008; Ojo, 2017). Kedua, penelitian tentang transparansi algoritma dan kepercayaan lebih banyak dikembangkan dalam konteks pengambilan keputusan otomatis, sistem rekomendasi, dan penerimaan AI, sehingga hubungan kedua variabel tersebut dengan keberhasilan sistem informasi berbasis Generative AI masih memerlukan pengujian lebih lanjut (Bitzer et al., 2023; Grimmelikhuijsen, 2023; Lockey et al., 2021). Ketiga, penelitian yang mengintegrasikan kualitas informasi, transparansi algoritma, dan kepercayaan pengguna dalam satu kerangka untuk menjelaskan keberhasilan sistem informasi berbasis Generative AI masih menjadi ruang pengembangan, terutama karena penelitian Fitriyani et al. (2026) lebih berorientasi pada adopsi Generative AI di perguruan tinggi daripada evaluasi keberhasilan sistem informasi secara multidimensional. Dengan demikian, penelitian ini diarahkan untuk mengisi kesenjangan konseptual dan empiris tersebut. Pemetaan pada Tabel 2 menunjukkan bahwa kepercayaan selama ini lebih sering diuji sebagai prediktor adopsi atau intensi (Choung et al., 2023; Fitriyani et al., 2026) dan sebagai mekanisme penghubung transparansi dengan perilaku (Ning et al., 2024), tetapi jarang diuji sebagai prediktor keberhasilan sistem informasi. Fitriyani et al. (2026) memang telah mengintegrasikan transparansi algoritma dan kepercayaan, namun variabel dependennya adalah adopsi dan modelnya tidak memasukkan kualitas informasi sebagai prediktor.

Kebaruan penelitian ini terletak pada pengembangan perspektif evaluasi keberhasilan sistem informasi berbasis Generative AI melalui integrasi tiga dimensi utama, yaitu kualitas informasi (information quality), transparansi algoritma (algorithmic transparency), dan kepercayaan pengguna (user trust). Berbeda dengan penelitian sebelumnya yang cenderung memisahkan evaluasi kualitas sistem informasi dari kajian penerimaan dan kepercayaan terhadap AI, penelitian ini berupaya membangun pemahaman yang lebih komprehensif mengenai faktor-faktor yang menentukan keberhasilan sistem dalam menghasilkan nilai bagi penggunanya. Kualitas informasi digunakan untuk mengevaluasi kelayakan dan keandalan keluaran sistem, transparansi algoritma digunakan untuk memahami keterbukaan proses serta kemampuan sistem menjelaskan hasil yang dihasilkan, sedangkan kepercayaan pengguna digunakan untuk mengidentifikasi keyakinan pengguna terhadap kompetensi dan reliabilitas sistem. Integrasi ketiga variabel tersebut diharapkan dapat memperluas penerapan model keberhasilan sistem informasi DeLone dan McLean dalam konteks teknologi generatif sekaligus memperkuat perspektif human-AI interaction. Kebaruan konseptual ini didasarkan pada pengembangan model keberhasilan sistem informasi, kajian multidimensional transparansi algoritma, dan penelitian mengenai kepercayaan manusia terhadap AI (DeLone & McLean, 2003; Bitzer et al., 2023; Lockey et al., 2021). Secara operasional, kebaruan penelitian ini terdiri atas tiga hal. Pertama, model ini memperluas model DeLone dan McLean dengan mengganti kualitas sistem dan kualitas layanan, yang relatif seragam pada platform Generative AI, dengan dua faktor evaluasi khas Generative AI, yaitu transparansi algoritma yang dipersepsikan dan kepercayaan pengguna. Kedua, berbeda dengan Fitriyani et al. (2026) yang memprediksi adopsi dan

Ning et al. (2024) yang menguji pemanfaatan saran algoritmik, penelitian ini menguji ketiga faktor sebagai prediktor langsung keberhasilan sistem informasi. Ketiga, penelitian ini menyediakan protokol pengukuran dan analisis yang dapat direplikasi, termasuk PLSpredict dan interval kepercayaan HTMT, sehingga hasil uji lapangan berikutnya dapat dibandingkan secara konsisten. Kebaruan ini bersifat inkremental, sedangkan pengujian peran mediasi kepercayaan atau moderasi literasi AI diajukan sebagai pengembangan berikutnya.

Berdasarkan latar belakang, urgensi, landasan teoretis, serta kesenjangan penelitian yang telah diuraikan, penelitian ini bertujuan untuk menganalisis keberhasilan sistem informasi berbasis Generative AI melalui kualitas informasi, transparansi algoritma, dan kepercayaan pengguna. Secara khusus, penelitian ini menguji tiga hubungan, yaitu (1) kualitas informasi terhadap keberhasilan sistem informasi (H1), (2) transparansi algoritma terhadap keberhasilan sistem informasi (H2), dan (3) kepercayaan pengguna terhadap keberhasilan sistem informasi (H3). Karena desain yang digunakan bersifat cross sectional, istilah pengaruh dalam hipotesis dimaknai sebagai hubungan prediktif secara statistik, bukan kausalitas pasti. Model konseptual dan ketiga hipotesis diringkas pada Gambar 1. Selain itu, penelitian ini diharapkan dapat memberikan kontribusi teoretis melalui pengembangan kerangka evaluasi keberhasilan sistem informasi yang mempertimbangkan karakteristik teknologi generatif, serta kontribusi praktis bagi pengembang dan organisasi dalam merancang sistem AI yang informatif, transparan, dan dapat dipercaya. Dengan demikian, hasil penelitian diharapkan tidak hanya memperkaya kajian akademik di bidang sistem informasi, tetapi juga memberikan dasar pertimbangan bagi pengembangan dan implementasi Generative AI yang berorientasi pada kebutuhan serta kepentingan pengguna (DeLone & McLean, 2003; Feuerriegel et al., 2024; Autio et al., 2024). Implikasi yang diharapkan meliputi dasar bagi pengembang platform untuk memprioritaskan fitur rujukan sumber dan pernyataan keterbatasan, masukan bagi regulator dalam menyusun pedoman transparansi layanan Generative AI, serta dasar bagi institusi pendidikan dan organisasi pengguna untuk menyusun pedoman verifikasi keluaran Generative AI.



Gambar 1. Model Konseptual Penelitian
Sumber: Dikembangkan dari DeLone dan McLean (2003), Bitzer et al. (2023), dan Glikson dan Woolley (2020).

METODE PENELITIAN

Jenis Penelitian (Type of Research)

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian eksplanatori (explanatory research), yaitu penelitian yang bertujuan menjelaskan hubungan prediktif antara variabel independen dan variabel dependen melalui pengujian hipotesis. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengukuran persepsi pengguna terhadap kualitas informasi, transparansi algoritma, dan kepercayaan pengguna dalam penggunaan sistem informasi berbasis Generative AI. Penelitian ini menggunakan desain cross-sectional survey, yaitu pengumpulan data yang dilakukan pada satu periode waktu tertentu untuk memperoleh gambaran empiris mengenai hubungan antarvariabel. Model penelitian menempatkan kualitas informasi (X1), transparansi algoritma (X2), dan kepercayaan pengguna (X3) sebagai variabel independen, sedangkan keberhasilan sistem informasi berbasis Generative AI (Y) sebagai variabel dependen. Pemilihan desain tersebut memungkinkan peneliti mengidentifikasi kontribusi masing-masing variabel dalam menjelaskan keberhasilan sistem informasi berdasarkan persepsi dan pengalaman pengguna (Creswell & Creswell, 2018; Saunders et al., 2019; Hair et al., 2022).

Desain Penelitian (Research Design)

Penelitian ini dirancang sebagai studi metodologis berbasis simulasi yang terdiri atas dua bagian, yaitu (1) penyusunan model konseptual dan protokol survei cross sectional bagi pengguna Generative AI di Indonesia, dan (2) demonstrasi prosedur evaluasi PLS-SEM menggunakan data sintetis yang dibangkitkan dari parameter populasi yang ditetapkan sebelumnya. Desain cross sectional hanya memungkinkan pengujian hubungan statistik berdasarkan persepsi pada satu waktu sehingga tidak dapat memastikan urutan sebab dan akibat sebagaimana desain eksperimen atau longitudinal. Data sintetis dibangkitkan pada November 2026 menggunakan skrip Python dengan seed 2026. Skor laten ketiga variabel independen dibangkitkan dari distribusi normal multivariat dengan korelasi 0,50 sampai 0,58, skor laten keberhasilan sistem informasi dibentuk dari koefisien populasi 0,30 (X1), 0,20 (X2), dan 0,34 (X3) ditambah galat acak, lalu setiap butir dibangkitkan dengan loading populasi 0,78 sampai 0,88 dan dikonversi menjadi skala Likert lima poin. Parameter tersebut ditetapkan sebagai skenario efek kecil sampai menengah yang sejalan dengan rentang koefisien pada studi terdahulu (Ojo, 2017; Fitriyani et al., 2026), sehingga hasil estimasi dapat dibandingkan dengan nilai populasi yang diketahui. Hasil pada bagian berikutnya diperlakukan sebagai ilustrasi prosedur, bukan sebagai temuan empiris.

Populasi, Sampel, Lokasi, dan Waktu Penelitian (Population, Sampling, Location, and Time)

Populasi dalam penelitian ini adalah pengguna individu berusia minimal 18 tahun di Indonesia yang pernah menggunakan sistem informasi berbasis Generative AI untuk mendukung aktivitas pencarian informasi, penyusunan dokumen, pembelajaran, pekerjaan profesional, maupun penyelesaian tugas lainnya. Sistem Generative AI yang menjadi konteks penelitian dapat mencakup ChatGPT, Google Gemini, Microsoft Copilot, Claude, dan platform sejenis yang mampu menghasilkan informasi secara otomatis berdasarkan instruksi pengguna. Teknik pengambilan sampel menggunakan purposive sampling, yaitu pemilihan responden berdasarkan karakteristik dan kriteria tertentu yang relevan dengan tujuan penelitian. Kriteria responden meliputi: (1) berusia minimal 18 tahun; (2) pernah menggunakan platform Generative AI minimal tiga kali dalam tiga bulan terakhir; (3) memiliki pengalaman menggunakan Generative AI untuk memperoleh atau

menghasilkan informasi; dan (4) bersedia berpartisipasi dalam penelitian. Jumlah sampel ditentukan menggunakan pendekatan power analysis dengan mempertimbangkan jumlah prediktor, tingkat signifikansi, kekuatan statistik, dan ukuran efek yang diharapkan. Perhitungan power analysis dengan uji F regresi berganda (tiga prediktor, $f^2 = 0{,}15$, $\alpha = 0{,}05$, power = 0,80) menghasilkan kebutuhan minimum 77 kasus, sedangkan metode inverse square root dengan koefisien jalur minimum yang diharapkan sebesar 0,20 menghasilkan kebutuhan minimum 155 kasus. Ukuran 200 kasus ditetapkan karena melampaui kedua batas tersebut (Etikan et al., 2016; Hair et al., 2022; Kock & Hadaya, 2018). Populasi sasaran protokol dibatasi pada pengguna Generative AI berusia minimal 18 tahun yang berdomisili di Indonesia, dengan rekrutmen daring melalui komunitas akademik, jaringan profesional, dan media sosial selama empat minggu. Pada artikel ini, protokol tersebut belum dijalankan di lapangan; sebagai gantinya, 200 kasus sintetis dibangkitkan pada November 2026 untuk mendemonstrasikan prosedur analisis, sehingga tidak terdapat kasus yang gugur pada tahap screening. Penggunaan purposive sampling melalui kanal daring membatasi generalisasi dan dicatat sebagai keterbatasan penelitian.

Instrumen Penelitian (Research Instrument)

Instrumen penelitian menggunakan kuesioner terstruktur (structured questionnaire) yang disusun berdasarkan indikator dari penelitian terdahulu dan disesuaikan dengan konteks penggunaan Generative AI. Pengukuran setiap variabel menggunakan skala Likert lima tingkat, yaitu 1 = sangat tidak setuju, 2 = tidak setuju, 3 = netral, 4 = setuju, dan 5 = sangat setuju. Variabel kualitas informasi diukur melalui indikator akurasi, relevansi, kelengkapan, ketepatan waktu, dan kemudahan pemahaman informasi. Variabel transparansi algoritma diukur melalui indikator keterbukaan proses, kejelasan mekanisme pembentukan keluaran, keterjelasan dasar informasi, penjelasan keterbatasan sistem, dan kemampuan sistem memberikan penjelasan yang dapat dipahami pengguna. Variabel kepercayaan pengguna diukur melalui indikator kompetensi, reliabilitas, integritas, dan keyakinan terhadap kemampuan sistem dalam menghasilkan informasi yang dapat diandalkan. Sementara itu, keberhasilan sistem informasi diukur melalui indikator kepuasan pengguna, intensi penggunaan berkelanjutan, dan persepsi manfaat bersih (net benefits) yang diperoleh pengguna. Penyusunan instrumen mengacu pada model keberhasilan sistem informasi DeLone dan McLean serta pengembangan konstruk kualitas informasi, transparansi algoritma, dan kepercayaan terhadap AI (DeLone & McLean, 2003; Petter et al., 2008; Bitzer et al., 2023). Setiap konstruk diukur dengan butir pernyataan yang diadaptasi dari skala terdahulu (Tabel 4), yaitu kualitas informasi dari Fu et al. (2024) dan Petter et al. (2008), transparansi algoritma dari Grimmelikhuijsen (2023) dan Liu (2021), kepercayaan pengguna dari Choung et al. (2023) dan Kaplan et al. (2023), serta keberhasilan sistem informasi dari DeLone dan McLean (2003) dan Marjanovic et al. (2024). Instrumen terdiri atas 17 butir. Protokol adaptasi bahasa menetapkan penerjemahan ke bahasa Indonesia dan penerjemahan balik ke bahasa Inggris oleh dua penerjemah independen. Seluruh konstruk dispesifikasikan sebagai konstruk reflektif karena butir merupakan manifestasi yang dapat saling dipertukarkan dari evaluasi yang sama. Untuk konstruk keberhasilan sistem informasi, kepuasan, intensi penggunaan berkelanjutan, dan manfaat bersih diperlakukan sebagai tiga manifestasi evaluasi keseluruhan pengguna, sedangkan pemodelan sebagai konstruk tingkat lebih tinggi (higher order construct) dengan beberapa butir per dimensi direkomendasikan untuk uji lapangan.

Tabel 3. Operasionalisasi Variabel Penelitian

No.	Variabel	Kode	Indikator
1	Kualitas Informasi (X1)	X1.1	Akurasi informasi
2	Kualitas Informasi (X1)	X1.2	Relevansi informasi
3	Kualitas Informasi (X1)	X1.3	Kelengkapan informasi
4	Kualitas Informasi (X1)	X1.4	Ketepatan waktu informasi
5	Kualitas Informasi (X1)	X1.5	Kemudahan memahami informasi
6	Transparansi Algoritma (X2)	X2.1	Keterbukaan proses algoritma
7	Transparansi Algoritma (X2)	X2.2	Kejelasan proses pembentukan informasi
8	Transparansi Algoritma (X2)	X2.3	Kejelasan dasar atau sumber informasi
9	Transparansi Algoritma (X2)	X2.4	Keterbukaan keterbatasan sistem
10	Transparansi Algoritma (X2)	X2.5	Kemampuan sistem memberikan penjelasan
11	Kepercayaan Pengguna (X3)	X3.1	Kompetensi sistem
12	Kepercayaan Pengguna (X3)	X3.2	Reliabilitas sistem
13	Kepercayaan Pengguna (X3)	X3.3	Integritas sistem
14	Kepercayaan Pengguna (X3)	X3.4	Keyakinan terhadap keluaran sistem
15	Keberhasilan Sistem Informasi (Y)	Y1	Kepuasan pengguna
16	Keberhasilan Sistem Informasi (Y)	Y2	Intensi penggunaan berkelanjutan
17	Keberhasilan Sistem Informasi (Y)	Y3	Manfaat bersih yang dirasakan

Sumber: Diadaptasi dari DeLone dan McLean (2003), Petter et al. (2008), dan Bitzer et al. (2023).

Tabel 4. Butir Pernyataan dan Sumber Skala

Kode	Butir pernyataan	Sumber adaptasi
X1.1	Informasi yang dihasilkan platform Generative AI yang saya gunakan akurat.	Fu et al. (2024); Petter et al. (2008)
X1.2	Informasi yang dihasilkan relevan dengan kebutuhan saya.	Fu et al. (2024); Petter et al. (2008)
X1.3	Informasi yang dihasilkan cukup lengkap untuk menyelesaikan tugas saya.	Fu et al. (2024); Petter et al. (2008)
X1.4	Informasi diberikan tepat pada saat saya membutuhkannya.	Fu et al. (2024); Petter et al. (2008)
X1.5	Informasi yang dihasilkan mudah saya pahami.	Fu et al. (2024); Petter et al. (2008)
X2.1	Platform menjelaskan secara umum cara sistem menghasilkan jawaban.	Grimmelikhuijsen (2023); Liu (2021)
X2.2	Saya memahami bagaimana jawaban dibentuk dari instruksi yang saya berikan.	Grimmelikhuijsen (2023); Liu (2021)
X2.3	Platform menunjukkan sumber atau dasar informasi yang digunakan.	Grimmelikhuijsen (2023); Liu (2021)
X2.4	Platform menyampaikan keterbatasan dan kemungkinan kesalahan jawabannya.	Grimmelikhuijsen (2023); Liu (2021)
X2.5	Platform memberikan penjelasan yang mudah dipahami ketika saya meminta alasan atas jawabannya.	Grimmelikhuijsen (2023); Liu (2021)

Kode	Butir pernyataan	Sumber adaptasi
X3.1	Platform memiliki kemampuan yang memadai untuk membantu tugas saya.	Choung et al. (2023); Kaplan et al. (2023)
X3.2	Platform memberikan jawaban yang konsisten dan dapat diandalkan.	Choung et al. (2023); Kaplan et al. (2023)
X3.3	Saya yakin platform menyajikan informasi secara jujur tanpa maksud menyesatkan.	Choung et al. (2023); Kaplan et al. (2023)
X3.4	Saya yakin dapat mengandalkan keluaran platform setelah memeriksanya seperlunya.	Choung et al. (2023); Kaplan et al. (2023)
Y1	Secara keseluruhan saya puas menggunakan platform Generative AI ini.	DeLone dan McLean (2003); Marjanovic et al. (2024)
Y2	Saya berniat terus menggunakan platform Generative AI ini di masa mendatang.	DeLone dan McLean (2003); Marjanovic et al. (2024)
Y3	Platform Generative AI ini meningkatkan efektivitas belajar atau bekerja saya.	DeLone dan McLean (2003); Marjanovic et al. (2024)

Sumber: Diadaptasi dari sumber pada kolom ketiga; seluruh butir menggunakan skala Likert lima poin.

Untuk memastikan instrumen dapat mengukur konstruk penelitian secara tepat, dilakukan pengujian validitas dan reliabilitas sebelum analisis hipotesis. Validitas isi (content validity) dirancang melalui penilaian ahli di bidang sistem informasi dan kecerdasan buatan. Selanjutnya, validitas konstruk dievaluasi melalui outer loading, Average Variance Extracted (AVE), dan validitas diskriminan menggunakan kriteria Heterotrait-Monotrait Ratio (HTMT). Reliabilitas instrumen dievaluasi menggunakan Cronbach's Alpha dan Composite Reliability dengan nilai yang umumnya diharapkan minimal 0,70. Pengujian tersebut bertujuan memastikan bahwa setiap indikator memiliki kemampuan pengukuran yang memadai serta mampu merepresentasikan konstruk penelitian secara konsisten (Hair et al., 2022; Franke & Sarstedt, 2019; DeVellis & Thorpe, 2021). Karena artikel ini menggunakan data sintetis, validasi isi oleh ahli dan pilot test belum dilaksanakan sehingga tidak dilaporkan sebagai hasil. Protokol menetapkan validasi isi oleh tiga ahli (sistem informasi, interaksi manusia dan AI, serta psikometri) dengan indeks Aiken's V minimal 0,80, diikuti pilot test terhadap 30 pengguna Generative AI dengan kriteria Cronbach's alpha minimal 0,70 sebelum survei utama, dan butir yang tidak memenuhi kriteria direvisi sebelum digunakan.

Teknik Pengumpulan Data (Data Collection Technique)

Pengumpulan data dalam penelitian ini menggunakan data primer yang diperoleh secara langsung dari responden melalui penyebaran kuesioner daring (online questionnaire) menggunakan Google Forms. Kuesioner disebarkan melalui media sosial, komunitas pengguna teknologi, jaringan profesional, serta lingkungan akademik yang memiliki pengalaman menggunakan Generative AI. Sebelum mengisi kuesioner utama, responden diberikan penjelasan mengenai tujuan penelitian, ruang lingkup penggunaan data, kerahasiaan identitas, dan hak untuk menghentikan partisipasi. Pengumpulan data dilakukan dengan menerapkan pertanyaan penyaringan (screening questions) untuk memastikan bahwa responden memenuhi kriteria sampel yang telah ditentukan. Selanjutnya, jawaban responden dikumpulkan dan diperiksa untuk mengidentifikasi data yang tidak lengkap, jawaban ganda, serta pola pengisian yang tidak wajar. Data yang memenuhi kriteria kemudian

dikodekan dan disiapkan untuk proses analisis statistik. Prosedur pengumpulan data ini dirancang agar data yang diperoleh relevan dengan tujuan penelitian dan mampu menggambarkan pengalaman aktual pengguna dalam berinteraksi dengan sistem Generative AI (Saunders et al., 2019; Creswell & Creswell, 2018; Podsakoff et al., 2024). Protokol menetapkan periode penyebaran empat minggu, tautan terpisah untuk setiap kanal rekrutmen, pembatasan satu respons per akun, pertanyaan perhatian (attention check), serta penghapusan kasus dengan data hilang lebih dari 10% atau pola jawaban seragam. Persetujuan responden diperoleh melalui halaman informed consent elektronik yang harus disetujui sebelum kuesioner dapat diisi, tidak ada data identitas yang dikumpulkan, dan data disimpan dalam berkas terenkripsi yang hanya dapat diakses tim peneliti. Pengendalian common method bias dilakukan secara prosedural melalui jaminan anonimitas, pemisahan blok butir prediktor dan kriterion, serta variasi redaksi butir, dan secara statistik melalui uji full collinearity VIF (Podsakoff et al., 2024). Persetujuan etik dari komite etik institusi perlu diperoleh sebelum survei lapangan dijalankan.

Prosedur Penelitian (Research Procedure)

Prosedur penelitian dilaksanakan secara sistematis melalui beberapa tahapan untuk memastikan setiap proses berjalan sesuai dengan tujuan dan rancangan penelitian. Tahapan tersebut dirinci pada Tabel 5. Pada artikel ini, tahap identifikasi masalah, studi literatur, pengembangan model, penyusunan instrumen, analisis data, interpretasi, dan penyusunan kesimpulan telah dilaksanakan, sedangkan validasi instrumen, pengumpulan data, dan pengolahan data lapangan disajikan sebagai protokol yang digantikan oleh pembangkitan data sintetis. Pelaksanaan prosedur secara bertahap diharapkan dapat meningkatkan konsistensi metodologis dan kualitas hasil penelitian (Creswell & Creswell, 2018; Saunders et al., 2019; Hair et al., 2022).

Tabel 5. Tahapan Prosedur Penelitian

No.	Tahapan	Aktivitas Penelitian	Hasil yang Diharapkan
1	Identifikasi masalah	Mengidentifikasi permasalahan dan fenomena penggunaan Generative AI	Rumusan masalah penelitian
2	Studi literatur	Mengkaji teori dan penelitian terdahulu	Landasan teori
3	Pengembangan model	Menentukan variabel dan merumuskan hipotesis	Model konseptual penelitian
4	Penyusunan instrumen	Menyusun indikator dan butir kuesioner	Instrumen penelitian
5	Validasi instrumen	Melakukan penilaian ahli dan pilot test	Instrumen yang layak digunakan
6	Pengumpulan data	Menyebarkan kuesioner kepada responden (protokol; pada artikel ini digantikan pembangkitan data sintetis n = 200)	Data primer
7	Pengolahan data	Melakukan coding, screening, dan data cleaning	Data siap dianalisis
8	Analisis data	Melakukan pengujian SEM-PLS	Hasil pengujian hipotesis
9	Interpretasi hasil	Menganalisis dan membahas hasil penelitian	Temuan penelitian
10	Kesimpulan	Menyusun kesimpulan dan implikasi penelitian	Artikel ilmiah

Teknik Analisis Data (Data Analysis Technique)

Teknik analisis data dalam penelitian ini menggunakan pendekatan Structural Equation Modeling–Partial Least Squares (SEM-PLS) dengan algoritma yang setara dengan pengaturan bawaan SmartPLS 4. Metode SEM-PLS dipilih karena penelitian bertujuan menguji hubungan prediktif antara beberapa konstruk laten, yaitu kualitas informasi, transparansi algoritma, kepercayaan pengguna, dan keberhasilan sistem informasi berbasis Generative AI. Selain itu, SEM-PLS memungkinkan pengujian model pengukuran (measurement model) dan model struktural (structural model) secara simultan. Analisis dilakukan melalui dua tahapan utama, yaitu evaluasi model pengukuran (outer model) dan evaluasi model struktural (inner model). Pendekatan ini sesuai untuk penelitian yang mengembangkan atau menguji hubungan antarvariabel dalam kerangka konseptual sistem informasi dan perilaku pengguna teknologi (Hair et al., 2022; Sarstedt et al., 2022; Franke & Sarstedt, 2019). SEM-PLS dipilih karena tujuan penelitian bersifat prediktif dan pengembangan teori, model memuat konstruk reflektif dengan jumlah butir yang berbeda, serta metode ini memungkinkan evaluasi daya prediksi di luar sampel melalui PLSpredict (Hair et al., 2022; Shmueli et al., 2019). Estimasi menggunakan algoritma PLS dengan path weighting scheme, Mode A untuk seluruh konstruk reflektif, kriteria henti 0,0000001, dan maksimum 3.000 iterasi, yang setara dengan pengaturan bawaan SmartPLS 4. Pada demonstrasi ini, algoritma tersebut dijalankan melalui skrip Python (NumPy dan SciPy) agar seluruh langkah dapat direplikasi, sedangkan pada uji lapangan analisis yang sama dapat dijalankan dengan SmartPLS 4. Data sintetis tidak memiliki data hilang; pada data lapangan, kasus dengan data hilang lebih dari 10% dihapus dan sisanya ditangani dengan mean replacement.

a. Evaluasi Model Pengukuran (Outer Model)

Evaluasi outer model dilakukan untuk mengetahui tingkat validitas dan reliabilitas indikator dalam merepresentasikan setiap variabel penelitian. Pengujian validitas konvergen dilakukan melalui nilai outer loading dengan nilai ideal ≥ 0,708 dan Average Variance Extracted (AVE) ≥ 0,50. Selanjutnya, validitas diskriminan diuji menggunakan metode HTMT dengan nilai yang direkomendasikan di bawah 0,90, atau di bawah 0,85 untuk kriteria yang lebih ketat. Pengujian reliabilitas dilakukan melalui Cronbach's Alpha dan Composite Reliability dengan nilai minimal 0,70. Apabila terdapat indikator yang tidak memenuhi kriteria, peneliti perlu mengevaluasi indikator tersebut berdasarkan pertimbangan statistik dan kesesuaian teoritis sebelum memutuskan untuk mempertahankan atau menghapusnya (Hair et al., 2022; Franke & Sarstedt, 2019; Sarstedt et al., 2022). Seluruh konstruk dispesifikasikan reflektif sehingga kriteria outer loading, AVE, dan reliabilitas berlaku untuk semua konstruk. Ambang HTMT 0,85 digunakan sebagai kriteria utama karena konstruk dalam model berbeda secara konseptual, sedangkan 0,90 hanya digunakan untuk konstruk yang sangat mirip, dan batas atas interval kepercayaan bootstrap 95% HTMT harus berada di bawah ambang tersebut (Franke & Sarstedt, 2019). Reliabilitas dilaporkan sebagai Cronbach's alpha, ρA, dan ρC, dengan nilai di atas 0,95 diwaspadai sebagai indikasi redundansi butir.

b. Evaluasi Model Struktural (Inner Model)

Evaluasi inner model bertujuan mengidentifikasi hubungan antarvariabel laten serta mengukur kemampuan variabel independen dalam menjelaskan variabel dependen. Pengujian dilakukan melalui beberapa tahapan, yaitu pengujian kolinearitas menggunakan Variance Inflation

Factor (VIF), pengujian koefisien determinasi (R^2), ukuran efek (f^2), dan daya prediksi di luar sampel melalui PLSpredict. Nilai R^2 digunakan untuk mengetahui proporsi variasi keberhasilan sistem informasi yang dapat dijelaskan oleh kualitas informasi, transparansi algoritma, dan kepercayaan pengguna. Nilai f^2 digunakan untuk mengetahui besarnya kontribusi masing-masing variabel independen terhadap variabel dependen. Daya prediksi dievaluasi dengan PLSpredict menggunakan validasi silang 10 fold dengan 10 pengulangan. Nilai Q^2predict di atas 0 menunjukkan prediksi lebih baik daripada nilai rata-rata, sedangkan perbandingan RMSE dan MAE PLS-SEM dengan model regresi linear (LM) menunjukkan tingkat daya prediksi, yaitu tinggi bila seluruh indikator lebih kecil, sedang bila sebagian besar lebih kecil, dan rendah bila hanya sebagian kecil yang lebih kecil. Nilai R^2 ditafsirkan dengan acuan 0,25 lemah, 0,50 moderat, dan 0,75 substansial, sedangkan f^2 dengan acuan 0,02 kecil, 0,15 menengah, dan 0,35 besar. VIF diperiksa pada level konstruk prediktor (inner VIF) dengan batas 3,3, ditambah full collinearity VIF untuk mendeteksi common method bias. Seluruh hasil pengujian diinterpretasikan berdasarkan kriteria statistik dan konteks penelitian, bukan hanya berdasarkan terpenuhinya nilai ambang tertentu (Hair et al., 2022; Shmueli et al., 2019).

c. Pengujian Hipotesis (Hypothesis Testing)

Pengujian hipotesis dilakukan menggunakan prosedur bootstrapping pada SEM-PLS dengan 5.000 subsampel untuk memperoleh nilai koefisien jalur (path coefficient), nilai t-statistic, dan p-value. Hubungan antarvariabel dinyatakan signifikan apabila nilai p-value lebih kecil dari 0,05 atau nilai t-statistic lebih besar dari 1,96 untuk pengujian dua arah pada tingkat signifikansi 5%. Pengujian ini dilakukan untuk mengetahui arah dan besarnya pengaruh kualitas informasi, transparansi algoritma, dan kepercayaan pengguna terhadap keberhasilan sistem informasi berbasis Generative AI. Hasil pengujian kemudian digunakan untuk menentukan apakah hipotesis penelitian diterima atau tidak didukung secara empiris. Interpretasi hasil juga mempertimbangkan besarnya koefisien jalur dan interval kepercayaan agar kesimpulan penelitian tidak hanya didasarkan pada signifikansi statistik (Hair et al., 2022; Streukens & Leroi-Werelds, 2016; Sarstedt et al., 2022). Pengujian dilakukan dua arah agar kemungkinan hubungan negatif tetap terdeteksi, interval kepercayaan 95% bias corrected dilaporkan untuk setiap koefisien jalur, dan perbedaan antarkoefisien diuji melalui interval kepercayaan bootstrap atas selisih koefisien (Streukens & Leroi-Werelds, 2016).

HASIL DAN PEMBAHASAN

Bagian ini menyajikan demonstrasi analisis terhadap 200 kasus sintetis yang merepresentasikan profil hipotetis pengguna aplikasi Generative Artificial Intelligence (GenAI), seperti ChatGPT, Gemini, Microsoft Copilot, dan Claude. Profil kasus disusun mengikuti kriteria sampel pada protokol, yaitu berusia minimal 18 tahun dan pernah menggunakan GenAI sekurang-kurangnya tiga kali dalam tiga bulan terakhir. Penggunaan kriteria tersebut dimaksudkan agar responden memiliki pengalaman yang cukup untuk menilai kualitas informasi, transparansi algoritma, kepercayaan pengguna, dan keberhasilan sistem informasi. Seluruh angka pada bagian ini berasal dari pengolahan data sintetis tersebut dan tidak boleh dibaca sebagai temuan lapangan. Karena data dibangkitkan dari parameter populasi yang diketahui, hasil estimasi juga dibandingkan dengan nilai populasi tersebut untuk menilai kinerja prosedur.

Profil sintetis ditetapkan dengan proporsi kasus perempuan berjumlah 112 orang (56%), sedangkan laki-laki berjumlah 88 orang (44%). Kelompok usia terbanyak berada pada rentang 18–25 tahun, yaitu 94 orang (47%), diikuti kelompok usia 26–35 tahun sebanyak 66 orang (33%). Dari sisi pendidikan, mayoritas responden merupakan lulusan sarjana sebanyak 108 orang (54%). Proporsi tersebut ditetapkan peneliti untuk keperluan ilustrasi dan tidak dimaksudkan menggambarkan demografi pengguna GenAI di Indonesia.

Platform yang paling banyak digunakan dalam data sintetis ini adalah ChatGPT sebanyak 112 responden (56%), diikuti Gemini sebanyak 48 responden (24%), Microsoft Copilot sebanyak 24 responden (12%), dan Claude atau platform lainnya sebanyak 16 responden (8%). Frekuensi penggunaan ditetapkan sebanyak 58 kasus (29%) setiap hari, 84 kasus (42%) beberapa kali seminggu, 38 kasus (19%) sekali seminggu, dan 20 kasus (10%) kurang dari sekali seminggu (Tabel 6). Pola penggunaan tersebut memberikan konteks bagi penilaian responden terhadap pengalaman berinteraksi dengan sistem GenAI. Dalam protokol, responden diminta menilai satu platform yang paling sering digunakan sehingga penilaian bersifat spesifik platform. Karena karakteristik transparansi tiap platform berbeda, uji lapangan perlu melengkapinya dengan multigroup analysis antarplatform apabila jumlah kasus per kelompok memadai.

Tabel 6. Karakteristik Kasus (Data Sintetis)

Karakteristik	Kategori	Frekuensi	Persentase
Jenis kelamin	Laki-laki	88	44%
	Perempuan	112	56%
Usia	18–25 tahun	94	47%
	26–35 tahun	66	33%
	36–45 tahun	28	14%
	Di atas 45 tahun	12	6%
Pendidikan	SMA/sederajat	36	18%
	Diploma	24	12%
	Sarjana	108	54%
	Pascasarjana	32	16%
Platform	ChatGPT	112	56%
	Gemini	48	24%
	Microsoft Copilot	24	12%
	Claude/lainnya	16	8%
Frekuensi penggunaan	Setiap hari	58	29%
	Beberapa kali seminggu	84	42%
	Sekali seminggu	38	19%
	Kurang dari sekali seminggu	20	10%

Statistik deskriptif pada Tabel 7 menunjukkan bahwa rata-rata skor konstruk berada pada rentang 3,531 sampai 3,668 dengan simpangan baku 0,846 sampai 0,903. Rata-rata terendah terdapat pada butir akurasi informasi (X1.1; 3,500) dan keterbukaan proses (X2.1; 3,525), sedangkan rata-rata tertinggi terdapat pada butir integritas (X3.3; 3,700).

Tabel 7. Statistik Deskriptif Konstruk (Data Sintetis)

Konstruk	Jumlah butir	Rata-rata	Simpangan baku	Butir rata-rata terendah
Kualitas Informasi (X1)	5	3,531	0,846	X1.1 (3,500)
Transparansi Algoritma (X2)	5	3,555	0,865	X2.1 (3,525)
Kepercayaan Pengguna (X3)	4	3,650	0,903	X3.2 (3,595)
Keberhasilan Sistem Informasi (Y)	3	3,668	0,848	Y3 (3,640)

Sumber: Hasil pengolahan data sintetis (n = 200).

Hasil Evaluasi Model Pengukuran (Outer Model)

Evaluasi model pengukuran dilakukan untuk memastikan bahwa indikator yang digunakan mampu mengukur konstruk penelitian secara valid dan reliabel. Pada data sintetis, model terdiri atas empat konstruk, yaitu kualitas informasi (X1), transparansi algoritma (X2), kepercayaan pengguna (X3), dan keberhasilan sistem informasi (Y). Pengujian dilakukan melalui nilai outer loading, average variance extracted (AVE), composite reliability, Cronbach's alpha, serta validitas diskriminan menggunakan heterotrait-monotrait ratio (HTMT). Konstruk dan indikator yang diuji identik dengan operasionalisasi pada Tabel 3.

Hasil estimasi pada data sintetis menunjukkan bahwa seluruh indikator memiliki outer loading di atas 0,708, dengan rentang 0,814 (X1.1) hingga 0,900 (X3.2) (Tabel 8). Nilai tersebut mengindikasikan bahwa setiap indikator memiliki kontribusi yang memadai dalam merefleksikan konstruk yang diukur. Dengan demikian, tidak ada indikator yang dihapus dan seluruh indikator dipertahankan untuk analisis berikutnya.

Tabel 8. Nilai Outer Loading (Data Sintetis)

Konstruk	Indikator	Outer Loading
Kualitas Informasi (X1)	X1.1 Akurasi	0,814
	X1.2 Relevansi	0,864
	X1.3 Kelengkapan	0,847
	X1.4 Ketepatan waktu	0,825
	X1.5 Mudah dipahami	0,825
Transparansi Algoritma (X2)	X2.1 Keterbukaan proses	0,853
	X2.2 Kejelasan proses pembentukan informasi	0,819
	X2.3 Kejelasan sumber/dasar informasi	0,820
	X2.4 Keterbukaan keterbatasan sistem	0,859
	X2.5 Kemampuan memberikan penjelasan	0,847
Kepercayaan Pengguna (X3)	X3.1 Kompetensi	0,892
	X3.2 Keandalan	0,900
	X3.3 Integritas	0,855
	X3.4 Keyakinan terhadap keluaran	0,897
Keberhasilan Sistem Informasi (Y)	Y1 Kepuasan pengguna	0,864

Konstruk	Indikator	Outer Loading
	Y2 Niat penggunaan berkelanjutan	0,891
	Y3 Manfaat bersih	0,881

Tabel 9 menunjukkan bahwa Cronbach's alpha berada pada rentang 0,852 sampai 0,909, ρA 0,860 sampai 0,917, dan ρC 0,911 sampai 0,936, sedangkan AVE berada pada rentang 0,698 sampai 0,785. Tidak ada nilai reliabilitas yang melampaui 0,95 sehingga tidak terdapat indikasi redundansi butir yang serius. Hasil tersebut menunjukkan bahwa konstruk memiliki konsistensi internal yang memadai dan mampu menjelaskan lebih dari separuh varians indikator-indikatornya. Dengan demikian, model pengukuran memenuhi kriteria reliabilitas dan validitas konvergen pada data sintetis.

Tabel 9. Reliabilitas dan Validitas Konvergen (Data Sintetis)

Konstruk	Cronbach's Alpha	ρA / ρC	AVE	Keterangan
Kualitas Informasi (X1)	0,891	0,894 / 0,920	0,698	Memenuhi
Transparansi Algoritma (X2)	0,895	0,897 / 0,923	0,705	Memenuhi
Kepercayaan Pengguna (X3)	0,909	0,917 / 0,936	0,785	Memenuhi
Keberhasilan Sistem Informasi (Y)	0,852	0,860 / 0,911	0,772	Memenuhi

Validitas diskriminan pada data sintetis dievaluasi menggunakan nilai HTMT. Nilai HTMT antarkonstruk berada pada rentang 0,559 sampai 0,690, seluruhnya di bawah ambang ketat 0,85, dan batas atas interval kepercayaan bootstrap 95% tertinggi adalah 0,780 pada pasangan kepercayaan pengguna dan keberhasilan sistem informasi (Tabel 10). Hal ini menunjukkan bahwa setiap konstruk memiliki perbedaan empiris yang memadai dari konstruk lainnya. Dengan demikian, kualitas informasi, transparansi algoritma, kepercayaan pengguna, dan keberhasilan sistem informasi dapat diperlakukan sebagai konstruk yang berbeda dalam model penelitian. Pasangan X3 dan Y memiliki HTMT tertinggi, sesuai dugaan konseptual bahwa kepercayaan berdekatan dengan kepuasan dan intensi penggunaan, tetapi intervalnya tidak mencapai 0,85 sehingga kedua konstruk dapat dibedakan pada data ini.

Tabel 10. Hasil Uji Validitas Diskriminan HTMT (Data Sintetis)

Pasangan Konstruk	HTMT	CI 95% dan Keterangan
X1 – X2	0,609	[0,494; 0,706]; Memenuhi
X1 – X3	0,559	[0,426; 0,675]; Memenuhi
X1 – Y	0,664	[0,560; 0,755]; Memenuhi
X2 – X3	0,592	[0,467; 0,699]; Memenuhi
X2 – Y	0,576	[0,452; 0,686]; Memenuhi
X3 – Y	0,690	[0,589; 0,780]; Memenuhi

Hasil Evaluasi Model Struktural (Inner Model)

Setelah model pengukuran dinyatakan memenuhi kriteria pada data sintetis, tahap berikutnya adalah mengevaluasi model struktural. Evaluasi dilakukan dengan memeriksa collinearity statistics (VIF), koefisien determinasi (R-square), effect size (f-square), serta daya prediksi melalui PLSpredict. Pemeriksaan dilakukan berurutan, yaitu kolinearitas, koefisien jalur dan signifikansinya, R^2, f^2, kemudian PLSpredict.

Nilai inner VIF pada level konstruk prediktor berada pada rentang 1,552 hingga 1,633 (Tabel 11). Nilai tersebut berada di bawah batas konservatif 3,3 sehingga tidak menunjukkan indikasi multikolinearitas yang mengkhawatirkan. Artinya, kualitas informasi, transparansi algoritma, dan kepercayaan pengguna dalam model ini tidak memiliki korelasi yang terlalu tinggi sehingga masing-masing masih dapat memberikan kontribusi dalam menjelaskan variabel keberhasilan sistem informasi. Uji full collinearity menghasilkan VIF 1,663 sampai 1,951 untuk keempat konstruk, di bawah 3,3, sehingga tidak terdapat indikasi common method bias yang serius. Data sintetis tidak memuat varians metode secara sengaja, sehingga uji ini terutama mendemonstrasikan prosedurnya.

Tabel 11. Hasil Uji Multikolinearitas (Data Sintetis)

Variabel Prediktor	VIF	Keterangan
Kualitas Informasi (X1)	1,572	Tidak bermasalah
Transparansi Algoritma (X2)	1,633	Tidak bermasalah
Kepercayaan Pengguna (X3)	1,552	Tidak bermasalah

Nilai R-square keberhasilan sistem informasi pada data sintetis adalah 0,488 dengan R^2 adjusted 0,480 (Tabel 12). Nilai tersebut menunjukkan bahwa 48,8% variasi keberhasilan sistem informasi dapat dijelaskan secara bersama-sama oleh kualitas informasi, transparansi algoritma, dan kepercayaan pengguna. Sementara itu, 51,2% sisanya berasal dari faktor yang tidak dimodelkan, misalnya kualitas sistem dan kualitas layanan yang secara sengaja dikeluarkan dari model, meskipun hal ini tidak dapat dipastikan tanpa pengujian tambahan. Nilai ini memberikan gambaran bahwa ketiga variabel independen memiliki kemampuan penjelasan yang mendekati kategori moderat (Hair et al., 2022). Nilai ini dekat dengan R^2 populasi laten yang ditetapkan pada pembangkitan data, yaitu 0,495.

Tabel 12. Nilai Koefisien Determinasi (Data Sintetis)

Variabel Endogen	R-Square	R-Square Adjusted	Interpretasi
Keberhasilan Sistem Informasi (Y)	0,488	0,480	Model menjelaskan 48,8% variasi Y; mendekati moderat

Nilai f^2 pada Tabel 13 menunjukkan bahwa kepercayaan pengguna memiliki efek menengah ($f^2 = 0{,}186$), kualitas informasi memiliki efek kecil ($f^2 = 0{,}129$), dan transparansi algoritma memiliki efek di bawah batas efek kecil ($f^2 = 0{,}018$). Nilai f^2 menggambarkan kontribusi relatif terhadap R^2 dalam model, bukan besaran pengaruh kausal.

Hasil PLSpredict pada Tabel 14 menunjukkan nilai Q^2predict positif untuk ketiga indikator keberhasilan sistem informasi (0,297 sampai 0,433). Nilai RMSE dan MAE PLS-SEM lebih kecil daripada model LM pada seluruh indikator, sehingga model memiliki daya prediksi di luar sampel

yang tinggi menurut kriteria Shmueli et al. (2019).

Tabel 13. Nilai Effect Size (Data Sintetis)

Variabel Prediktor	f-square	Interpretasi
Kualitas Informasi (X1)	0,129	Efek kecil
Transparansi Algoritma (X2)	0,018	Di bawah efek kecil
Kepercayaan Pengguna (X3)	0,186	Efek menengah

Tabel 14. Hasil PLSpredict (Data Sintetis)

Indikator	Q²predict	RMSE (PLS-SEM / LM)	MAE (PLS-SEM / LM)	Keterangan
Y1	0,297	0,778 / 0,802	0,628 / 0,650	PLS-SEM lebih kecil
Y2	0,433	0,769 / 0,798	0,622 / 0,626	PLS-SEM lebih kecil
Y3	0,337	0,777 / 0,816	0,607 / 0,640	PLS-SEM lebih kecil

Sumber: Hasil PLSpredict, validasi silang 10 fold dengan 10 pengulangan.

Hasil Pengujian Hipotesis

Pengujian hipotesis pada data sintetis dilakukan melalui prosedur bootstrapping dengan 5.000 subsampel dan tingkat signifikansi 5% (two-tailed). Hubungan dinyatakan signifikan apabila nilai p-value lebih kecil dari 0,05. Koefisien jalur positif menunjukkan bahwa peningkatan pada variabel prediktor diikuti peningkatan pada keberhasilan sistem informasi, dengan asumsi variabel lain dalam model tetap. Hipotesis H1 sampai H3 telah dirumuskan pada bagian pendahuluan, sedangkan interval kepercayaan 95% bias corrected dilaporkan pada Tabel 15 dan Gambar 2.

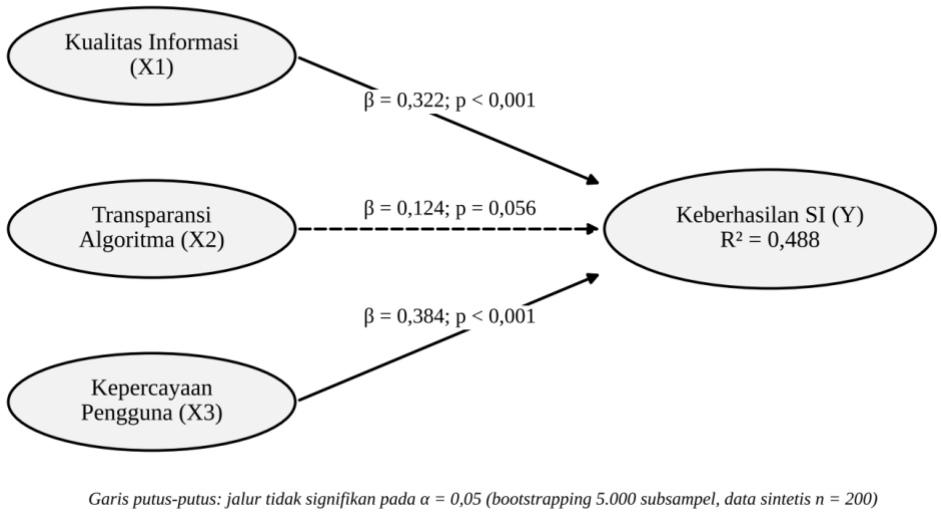
Kualitas informasi memiliki koefisien jalur 0,322 ($t = 5,271$; $p < 0,001$; CI 95% [0,197; 0,435]), sehingga H1 didukung pada data sintetis. Estimasi ini dekat dengan koefisien populasi 0,30, yang menunjukkan bahwa prosedur mampu memulihkan efek kualitas informasi secara akurat pada 200 kasus.

Transparansi algoritma memiliki koefisien jalur 0,124 ($t = 1,911$; $p = 0,056$; CI 95% [−0,007; 0,243]), sehingga H2 tidak didukung pada taraf 5%, padahal koefisien populasi yang ditetapkan adalah 0,20. Hasil ini menunjukkan bahwa efek kecil transparansi dapat tidak terdeteksi pada 200 kasus ketika terdapat kesalahan pengukuran dan korelasi antarprediktor, sehingga uji lapangan memerlukan ukuran sampel yang lebih besar atau desain yang memisahkan efek transparansi. Di antara indikator transparansi, keterbukaan keterbatasan sistem (X2.4) memiliki loading tertinggi (0,859), sedangkan keterbukaan proses (X2.1) memiliki rata-rata skor terendah (3,525).

Kepercayaan pengguna memiliki koefisien jalur 0,384 ($t = 6,192$; $p < 0,001$; CI 95% [0,263; 0,505]), sehingga H3 didukung pada data sintetis. Koefisien ini merupakan yang terbesar, tetapi selisihnya dengan kualitas informasi (0,062) tidak signifikan karena interval kepercayaan bootstrap selisih tersebut mencakup nol ([−0,132; 0,278]). Dengan demikian, kepercayaan tidak dapat dinyatakan sebagai prediktor yang lebih kuat daripada kualitas informasi. Kedekatan konseptual antara kepercayaan dan konstruk Y juga telah diperiksa melalui HTMT (0,690; CI 95% [0,589; 0,780]).

Tabel 15. Hasil Pengujian Hipotesis (Data Sintetis)

Hipotesis	Koefisien Jalur	T-Statistic	P-Value	CI 95% dan Keputusan
H1: X1 → Y	0,322	5,271	<0,001	[0,197; 0,435]; Didukung
H2: X2 → Y	0,124	1,911	0,056	[−0,007; 0,243]; Tidak didukung
H3: X3 → Y	0,384	6,192	<0,001	[0,263; 0,505]; Didukung



Gambar 2. Model Struktural Hasil Estimasi (Data Sintetis)
Sumber: Hasil pengolahan data sintetis (n = 200), bootstrapping 5.000 subsampel.

Pada data sintetis, dua dari tiga hipotesis didukung, sedangkan H2 tidak didukung. Hasil ini mendukung argumentasi konseptual bahwa keberhasilan sistem informasi berbasis GenAI tidak hanya ditentukan oleh kualitas keluaran informasi, tetapi juga oleh kepercayaan pengguna. Sesuai posisi artikel sebagai studi metodologis, hasil ini berfungsi menguji kelayakan prosedur analisis dan memperlihatkan pola yang perlu diverifikasi, bukan menetapkan simpulan empiris tentang populasi pengguna GenAI.

Pembahasan

Pada data sintetis, kualitas informasi berhubungan positif dengan keberhasilan sistem informasi berbasis GenAI. Temuan ilustratif ini sejalan dengan model keberhasilan sistem informasi DeLone dan McLean yang menempatkan kualitas informasi sebagai salah satu dimensi utama dalam membentuk kepuasan dan manfaat penggunaan sistem. Dalam konteks GenAI, kualitas informasi menjadi penting karena pengguna memanfaatkan keluaran sistem untuk memahami persoalan, menyelesaikan pekerjaan, dan mendukung pengambilan keputusan. Oleh sebab itu, informasi yang relevan, akurat, lengkap, dan mudah dipahami dapat meningkatkan nilai guna sistem bagi pengguna (DeLone & McLean, 2003; Petter et al., 2008; Fu et al., 2024). Besaran koefisien 0,322 lebih besar daripada temuan Ojo (2017) pada sistem informasi rumah sakit (β = 0,24 terhadap penggunaan dan β = 0,17 terhadap kepuasan). Perbedaan tersebut perlu ditafsirkan hati-hati karena koefisien pada data sintetis ditentukan oleh parameter populasi yang ditetapkan, meskipun secara konseptual mutu

keluaran dapat lebih menentukan pada Generative AI karena pengguna memanfaatkan informasi yang dihasilkan secara langsung, bukan sekadar data yang tersimpan. Pola ini sejalan dengan Fu et al. (2024) yang menemukan kelengkapan, presisi, dan ketepatan waktu sebagai penentu kepuasan informasi ChatGPT pada pengguna perguruan tinggi di Indonesia, serta dengan Marjanovic et al. (2024) yang menunjukkan bahwa model DeLone dan McLean dapat diterapkan untuk mengevaluasi ChatGPT.

Transparansi algoritma tidak berhubungan signifikan dengan keberhasilan sistem informasi pada data sintetis, meskipun koefisiennya positif. Pola ini, apabila terkonfirmasi pada data lapangan, sejalan dengan Wang dan Ding (2024) yang menemukan bahwa penjelasan AI tidak selalu meningkatkan kepercayaan yang dilaporkan secara subjektif, serta dengan Fitriyani et al. (2026), Grimmelikhuijsen (2023), dan Ning et al. (2024) yang menunjukkan bahwa transparansi lebih banyak bekerja melalui persepsi kontrol, kegunaan, atau kepercayaan daripada secara langsung. Hal ini memperkuat alasan untuk menguji kepercayaan sebagai mediator pada penelitian lanjutan. Pengguna perlu mengetahui bahwa keluaran sistem dapat memiliki keterbatasan, termasuk kemungkinan kesalahan atau informasi yang tidak didukung sumber memadai. Transparansi yang mudah dipahami dapat membantu pengguna menilai hasil secara kritis dan menentukan apakah informasi layak digunakan. Dengan demikian, transparansi bukan sekadar aspek teknis, tetapi juga berkaitan dengan akuntabilitas dan kualitas interaksi antara manusia dan sistem AI (Ananny & Crawford, 2018; Rai, 2020; Shin, 2021). Bagi platform Generative AI yang tidak membuka seluruh mekanisme algoritmanya, Ananny dan Crawford (2018) mengingatkan bahwa keterbukaan tidak otomatis menghasilkan pemahaman. Karena itu, bentuk transparansi yang paling relevan bagi pengguna adalah pernyataan keterbatasan dan rujukan sumber yang dapat diperiksa, sejalan dengan indikator X2.4 yang memiliki loading tertinggi.

Kepercayaan pengguna memperoleh koefisien jalur terbesar pada data sintetis, tetapi tidak berbeda signifikan dari kualitas informasi. Hal ini mengilustrasikan bahwa persepsi terhadap kompetensi, keandalan, dan integritas sistem dapat berperan penting dalam penilaian keberhasilan GenAI. Pengguna cenderung menilai sistem secara positif apabila pengalaman interaksi menunjukkan konsistensi dan manfaat yang sesuai harapan. Namun, kepercayaan yang baik bukan berarti pengguna menerima seluruh jawaban tanpa verifikasi. Kepercayaan yang proporsional perlu berjalan bersama pemahaman terhadap keterbatasan teknologi dan kemampuan mengevaluasi informasi (Glikson & Woolley, 2020; Kaplan et al., 2023; Lockey et al., 2021). Pola ini konsisten dengan Fitriyani et al. (2026) yang menemukan kepercayaan sebagai prediktor terkuat intensi perilaku ($\beta = 0{,}623$), meskipun besaran koefisien pada penelitian ini lebih kecil karena variabel dependennya mencakup kepuasan dan manfaat bersih, bukan hanya intensi. Karena kepercayaan berdekatan secara konseptual dengan kepuasan dan intensi, uji lapangan perlu memastikan bahwa peran kepercayaan tetap bertahan setelah validitas diskriminan dan kemungkinan tumpang tindih tersebut diperiksa, sebagaimana juga ditekankan Wang dan Ding (2024) mengenai perbedaan kepercayaan perilaku dan kepercayaan subjektif.

Implikasi Teoretis

Secara teoretis, demonstrasi ini memperlihatkan bagaimana model DeLone dan McLean dapat diadaptasi untuk Generative AI dengan menggantikan kualitas sistem dan kualitas layanan oleh dua faktor khas Generative AI. Pola pada data sintetis menunjukkan bahwa kontribusi langsung transparansi algoritma kemungkinan kecil, sehingga perluasan model yang paling menjanjikan

adalah menempatkan transparansi sebagai anteseden kepercayaan dan kualitas informasi yang dipersepsikan, bukan sebagai prediktor sejajar. Proposisi ini menjawab celah ketiga pada pendahuluan dan memberikan arah pengujian yang lebih tajam bagi data lapangan (DeLone & McLean, 2003; Ning et al., 2024; Mijač, 2025).

Implikasi Praktis

Implikasi praktis dari pembahasan ini adalah pengembang GenAI perlu meningkatkan kualitas jawaban, memberikan penjelasan yang jelas mengenai keterbatasan sistem, serta menyediakan dukungan bagi pengguna untuk memeriksa informasi. Organisasi yang mengadopsi GenAI juga perlu mengembangkan pedoman penggunaan yang menekankan verifikasi informasi, perlindungan data, dan tanggung jawab pengguna. Dengan demikian, keberhasilan implementasi GenAI tidak hanya bergantung pada kemampuan teknologi, tetapi juga pada tata kelola dan kesiapan pengguna dalam memanfaatkannya secara tepat (Dwivedi et al., 2023; Rai, 2020; Feuerriegel et al., 2024). Secara lebih spesifik, butir dengan rata-rata terendah pada data sintetis, yaitu akurasi informasi dan keterbukaan proses, menunjukkan cara menentukan prioritas apabila pola serupa muncul pada data lapangan. Pengembang platform dapat memprioritaskan rujukan sumber yang dapat diverifikasi dan pernyataan keterbatasan yang kontekstual, organisasi dan institusi pendidikan dapat menyusun pedoman verifikasi keluaran Generative AI sebelum digunakan untuk keputusan, sedangkan pengguna akhir memerlukan pelatihan literasi AI agar kepercayaannya tetap terkalibrasi.

Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan. Pertama, seluruh hasil berasal dari data sintetis sehingga tidak dapat digeneralisasi ke populasi pengguna Generative AI. Kedua, desain cross sectional dan purposive sampling melalui kanal daring pada protokol membatasi inferensi kausal dan generalisasi. Ketiga, pengukuran berbasis self report rentan terhadap bias persepsi dan common method bias. Keempat, model belum membedakan platform Generative AI dan belum memodelkan keberhasilan sistem informasi sebagai konstruk tingkat lebih tinggi. Kelima, data sintetis dibangkitkan tanpa varians metode dan tanpa data hilang, sehingga kondisinya lebih ideal daripada data lapangan.

KESIMPULAN

Penelitian ini menghasilkan model evaluasi keberhasilan sistem informasi berbasis GenAI yang mengintegrasikan kualitas informasi, transparansi algoritma, dan kepercayaan pengguna, beserta protokol pengukuran dan analisis PLS-SEM yang dapat direplikasi. Demonstrasi pada 200 kasus sintetis menunjukkan bahwa kualitas informasi (H1) dan kepercayaan pengguna (H3) berhubungan positif dan signifikan dengan keberhasilan sistem informasi, sedangkan transparansi algoritma (H2) tidak signifikan, dan model menjelaskan 48,8% variasi keberhasilan dengan daya prediksi di luar sampel yang tinggi.

Karena seluruh angka berasal dari data sintetis, hasil tersebut tidak dapat diperlakukan sebagai simpulan empiris. Kontribusi utamanya adalah memperlihatkan kelayakan prosedur evaluasi dan risiko tidak terdeteksinya efek kecil transparansi algoritma pada 200 kasus.

Dengan demikian, penelitian ini mengusulkan bahwa keberhasilan sistem informasi berbasis GenAI perlu dievaluasi melalui pendekatan yang tidak hanya berorientasi pada aspek teknis, tetapi juga memperhatikan kualitas informasi dan pengalaman pengguna. Pengembang teknologi GenAI perlu meningkatkan akurasi keluaran, menyediakan penjelasan yang transparan mengenai kemampuan dan keterbatasan sistem, serta membangun kepercayaan pengguna melalui layanan

yang konsisten dan dapat diandalkan. Langkah berikutnya yang paling mendesak adalah menjalankan protokol ini pada responden riil dengan ukuran sampel yang memadai untuk efek kecil, menguji kepercayaan sebagai mediator transparansi, membandingkan platform melalui multigroup analysis, serta mempertimbangkan faktor lain, seperti kualitas sistem, persepsi risiko, literasi AI, dan perlindungan privasi, guna memperoleh pemahaman yang lebih komprehensif mengenai keberhasilan penerapan GenAI. Keterbatasan desain cross sectional, purposive sampling, dan pengukuran self report juga perlu diperhitungkan dalam menafsirkan hasil lapangan.

PENDANAAN

Penulis menyatakan bahwa tidak ada dukungan finansial yang diterima untuk pelaksanaan penelitian ini dan/atau penerbitan artikel ini.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa penelitian ini dilakukan tanpa adanya hubungan komersial atau finansial yang dapat ditafsirkan sebagai potensi konflik kepentingan.

KONTRIBUSI PENULIS

Lanny Suryani Rohimah: konseptualisasi, metodologi, analisis formal, dan penulisan draf awal. Mar'atus Solikhah: kajian literatur, validasi, serta penulisan reviu dan penyuntingan. Seluruh penulis telah membaca dan menyetujui naskah akhir.

PERNYATAAN PENGGUNAAN KECERDASAN ARTIFISIAL GENERATIF

Penulis menyatakan bahwa AI generatif digunakan dalam penyusunan naskah ini. Penulis mengakui penggunaan AI generatif untuk menyempurnakan kejelasan bahasa dan struktur tata bahasa dalam naskah ini. Penggunaan teknologi ini dilakukan dengan mematuhi pedoman etika yang berlaku terkait penggunaan dan pengungkapan AI generatif dalam penelitian ilmiah. Setiap penulis telah memberikan kontribusi intelektual yang substansial terhadap penelitian ini, yang telah diperiksa secara cermat untuk memastikan akurasinya; penulis bertanggung jawab penuh atas integritas dan konten akhir naskah ini. AI generatif juga digunakan untuk membantu menyusun skrip Python pembangkit data sintetis dan analisis PLS-SEM yang digunakan pada bagian Hasil; seluruh parameter, keluaran, dan penafsirannya telah diperiksa oleh penulis.

REFERENSI

Ananny, M., & Crawford, K. (2018). Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability. New Media & Society, 20(3), 973–989. https://doi.org/10.1177/1461444816676645

Autio, C., Schwartz, R., Dunietz, J., Jain, S., Stanley, M., Tabassi, E., Hall, P., & Roberts, K. (2024). Artificial intelligence risk management framework: Generative artificial intelligence profile. National Institute of Standards and Technology. https://doi.org/10.6028/NIST.AI.600-1

Bick, A., Blandin, A., & Deming, D. J. (2024). The rapid adoption of generative AI (NBER Working Paper No. 32966). National Bureau of Economic Research. https://doi.org/10.3386/w32966

Bitzer, T., Wiener, M., & Cram, W. A. (2023). Algorithmic transparency: Concepts, antecedents, and consequences – A review and research framework. Communications of the Association for Information Systems, 52, 293–331. https://doi.org/10.17705/1CAIS.05214

Choung, H., David, P., & Ross, A. (2023). Trust in AI and its role in the acceptance of AI

technologies. International Journal of Human–Computer Interaction, 39(9), 1727–1739. https://doi.org/10.1080/10447318.2022.2050543

Creswell, J. W., & Creswell, J. D. (2018). Research design: Qualitative, quantitative, and mixed methods approaches (5th ed.). SAGE Publications.

DeLone, W. H., & McLean, E. R. (1992). Information systems success: The quest for the dependent variable. Information Systems Research, 3(1), 60–95. https://doi.org/10.1287/isre.3.1.60

DeLone, W. H., & McLean, E. R. (2003). The DeLone and McLean model of information systems success: A ten-year update. Journal of Management Information Systems, 19(4), 9–30. https://doi.org/10.1080/07421222.2003.11045748

DeVellis, R. F., & Thorpe, C. T. (2021). Scale development: Theory and applications (5th ed.). SAGE Publications.

Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., Baabdullah, A. M., Koohang, A., Raghavan, V., Ahuja, M., Albanna, H., Albashrawi, M. A., Al-Busaidi, A. S., Balakrishnan, J., Barlette, Y., Basu, S., Bose, I., Brooks, L., Buhalis, D., . . . Wright, R. (2023). So what if ChatGPT wrote it? Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy. International Journal of Information Management, 71, Article 102642. https://doi.org/10.1016/j.ijinfomgt.2023.102642

Etikan, I., Musa, S. A., & Alkassim, R. S. (2016). Comparison of convenience sampling and purposive sampling. American Journal of Theoretical and Applied Statistics, 5(1), 1–4. https://doi.org/10.11648/j.ajtas.20160501.11

Farquhar, S., Kossen, J., Kuhn, L., & Gal, Y. (2024). Detecting hallucinations in large language models using semantic entropy. Nature, 630, 625–630. https://doi.org/10.1038/s41586-024-07421-0

Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. Business & Information Systems Engineering, 66, 111–126. https://doi.org/10.1007/s12599-023-00834-7

Fitriyani, B. Y., Imtihan, K., Amrullah, Ashari, M., & Bagye, W. (2026). Modeling Generative AI adoption in higher education: The role of interface quality, algorithmic transparency, and trust in human-AI interaction. Journal of Information Systems and Informatics, 8(3), 2759–2795. https://doi.org/10.63158/journalisi.v8i3.1598

Franke, G., & Sarstedt, M. (2019). Heuristics versus statistics in discriminant validity testing: A comparison of four procedures. Internet Research, 29(3), 430–447. https://doi.org/10.1108/IntR-12-2017-0515

Fu, C.-J., Silalahi, A. D. K., Shih, I.-T., Phuong, D. T. T., Eunike, I. J., & Jargalsaikhan, S. (2024). Assessing ChatGPT's information quality through the lens of user information satisfaction and information quality theory in higher education: A theoretical framework. Human Behavior and Emerging Technologies, 2024, Article 8114315. https://doi.org/10.1155/2024/8114315

Glikson, E., & Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. Academy of Management Annals, 14(2), 627–660. https://doi.org/10.5465/annals.2018.0057

Grimmelikhuijsen, S. (2023). Explaining why the computer says no: Algorithmic transparency

affects the perceived trustworthiness of automated decision-making. Public Administration Review, 83(2), 241–262. https://doi.org/10.1111/puar.13483

Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). A primer on partial least squares structural equation modeling (PLS-SEM) (3rd ed.). SAGE Publications.

Kaplan, A. D., Kessler, T. T., Brill, J. C., & Hancock, P. A. (2023). Trust in artificial intelligence: Meta-analytic findings. Human Factors, 65(2), 337–359. https://doi.org/10.1177/00187208211013988

Kock, N., & Hadaya, P. (2018). Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. Information Systems Journal, 28(1), 227–261. https://doi.org/10.1111/isj.12131

Li, J., Cheng, X., Zhao, W. X., Nie, J.-Y., & Wen, J.-R. (2023). HaluEval: A large-scale hallucination evaluation benchmark for large language models. Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing, 6449–6464. https://doi.org/10.18653/v1/2023.emnlp-main.397

Liu, B. (2021). In AI we trust? Effects of agency locus and transparency on uncertainty reduction in human–AI interaction. Journal of Computer-Mediated Communication, 26(6), 384–402. https://doi.org/10.1093/jcmc/zmab013

Lockey, S., Gillespie, N., Holm, D., & Someh, I. A. (2021). A review of trust in artificial intelligence: Challenges, vulnerabilities and future directions. Proceedings of the 54th Hawaii International Conference on System Sciences, 5463–5472. https://doi.org/10.24251/HICSS.2021.664

Marjanovic, U., Mester, G., & Milic Marjanovic, B. (2024). Assessing the success of artificial intelligence tools: An evaluation of ChatGPT using the information system success model. Interdisciplinary Description of Complex Systems, 22(3), 266–275. https://doi.org/10.7906/indecs.22.3.3

Mijač, T. (2025). Rethinking information system success: Generative AI in the hands of future business managers. e-mentor, 5(112), 47–56. https://doi.org/10.15219/em112.1730

Ning, X., Lu, Y., Li, W., & Gupta, S. (2024). How transparency affects algorithmic advice utilization: The mediating roles of trusting beliefs. Decision Support Systems, 183, Article 114273. https://doi.org/10.1016/j.dss.2024.114273

Ojo, A. I. (2017). Validation of the DeLone and McLean information systems success model. Healthcare Informatics Research, 23(1), 60–66. https://doi.org/10.4258/hir.2017.23.1.60

Petter, S., DeLone, W., & McLean, E. (2008). Measuring information systems success: Models, dimensions, measures, and interrelationships. European Journal of Information Systems, 17(3), 236–263. https://doi.org/10.1057/ejis.2008.15

Podsakoff, P. M., Podsakoff, N. P., Williams, L. J., Huang, C., & Yang, J. (2024). Common method bias: It's bad, it's complex, it's widespread, and it's not easy to fix. Annual Review of Organizational Psychology and Organizational Behavior, 11, 17–61. https://doi.org/10.1146/annurev-orgpsych-110721-040030

Rai, A. (2020). Explainable AI: From black box to glass box. Journal of the Academy of Marketing Science, 48(1), 137–141. https://doi.org/10.1007/s11747-019-00710-5

Sarstedt, M., Ringle, C. M., & Hair, J. F. (2022). Partial least squares structural equation modeling. In C. Homburg, M. Klarmann, & A. Vomberg (Eds.), Handbook of market research (pp.

587–632). Springer. https://doi.org/10.1007/978-3-319-57413-4_15

Saunders, M., Lewis, P., & Thornhill, A. (2019). Research methods for business students (8th ed.). Pearson Education.

Shin, D. (2021). The effects of explainability and causability on perception, trust, and acceptance: Implications for explainable AI. International Journal of Human-Computer Studies, 146, Article 102551. https://doi.org/10.1016/j.ijhcs.2020.102551

Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: Guidelines for using PLSpredict. European Journal of Marketing, 53(11), 2322–2347. https://doi.org/10.1108/EJM-02-2019-0189

Streukens, S., & Leroi-Werelds, S. (2016). Bootstrapping and PLS-SEM: A step-by-step guide to get more out of your bootstrap results. European Management Journal, 34(6), 618–632. https://doi.org/10.1016/j.emj.2016.06.003

Wang, P., & Ding, H. (2024). The rationality of explanation or human capacity? Understanding the impact of explainable artificial intelligence on human-AI trust and decision performance. Information Processing & Management, 61(4), 103732. https://doi.org/10.1016/j.ipm.2024.103732