BAB II

TINJAUAN PUSTAKA

2.1. Studi Sebelumnya

Bagian ini menguraikan penelitian-penelitian terdahulu yang relevan dengan topik perpindahan pengguna *(switching intention)* pada platform AI generatif menggunakan kerangka *Push-Pull-Mooring* (PPM). Pemilihan literatur didasarkan pada kesesuaian variabel, metode, dan konteks penelitian dengan model yang diusulkan, mencakup aspek *push factor*, *pull factor*, *mooring factor*, serta penggunaan kerangka IS Success Model DeLone & McLean.

Zhou dan Li melakukan penelitian yang paling relevan dan menjadi landasan utama penelitian ini. Penelitian tersebut bertujuan menguji *switching intention* pengguna antar platform AI generatif menggunakan kerangka PPM. Dengan melibatkan 376 responden di Tiongkok yang telah berpengalaman menggunakan AI generatif penelitian ini menggunakan pendekatan *mixed-method* yang menggabungkan *Structural Equation Modeling* (SEM) dan *fuzzy-set Qualitative Comperative (fsQCA)*. *Push factors* yang diteliti Adalah *information hallucination* dan *privacy risk* yang keduanya mempengaruhi *dissatisfaction*. *Pull factors* terdiri dari *perceived interctivity*, *perceived authropomorphism*, dan *perceived personalization* yang mempengaruhi *user experience* . *Switching costs* berperan sebagai *mooring factor*. Hasil SEM menunjukan bahwa *information hallucination* (β = 0,284, p < 0,001) dan *privacy risk* (β = 0,384, p < 0,001) secara signifikan mempengaruhi *dissatisfaction*, sementara *perceived interactivity* (β = 0,301, p < 0,001) dan *perceived personalization* (β = 0,279, p < 0,001) secara signifikan mempengaruhi *user experience* . *Perceived anthropomorphism* tidak terbukti signifikan terhadap *user experience* . *Dissatisfaction* (β = 0,289, p < 0,001) dan *user experience* (β = 0,320, p < 0,001) positif memengaruhi *switching intention*, sementara *switching costs* berpengaruh negatif langsung (β = −0,375, p < 0,001) dan memoderasi hubungan *dissatisfaction* (β = −0,150, p < 0,01) serta *user experience* (β = −0,128, p < 0,01) dengan *switching intention*. Hasil fsQCA mengindentifikasi tiga konfigurasi yang memicu *switching intention*, di mana *dissatisfaction* merupakan *core condition* yang paling konsisten. Keterbatasan

utama penelitian ini adalah konteks yang terbatas pada pengguna di Tiongkok dan belum memasukan variable *System Quality*, *Information Quality* dan *Alternative Attractiveness* ke dalam model [4].

Jo dan Park meneliti *switching intention* pengguna sistem *Enterprise Resource Planning* (ERP) menggunakan kerangka PPM dengan penekanan khusus pada peran *information quality*. Dengan melibatkan 236 responden di Korea Selatan melalui analisis PLS-SEM, penelitian ini menemukan bahwa *System Quality*, *Information Quality*, dan dukungan manajemen puncak berpengaruh signifikan terhadap kepuasan pengguna, yang selanjutnya mempengaruhi *switching intention*. Secara khusus, *Information Quality* terbukti sebagai antesedan kepuasan yang paling dominan sesuai dengan judul penelitian yang secara eksplisit menekankan "*the important role of information quality*". Lebih lanjut, *Alternative Attractiveness* ditemukan sebagai predictor terkuat *switching intention* dalam model mereka dengan koefisien jalur sebesar 0,709 ($p < 0,001$). Penelitian ini menjadi justifikasi empiris yang kuat untuk mengintegrasikan *System Quality*, *Information Quality*, dan ke dalam model PPM untuk platform AI generatif [9].

Susanti et al. meneliti faktor-faktor yang memengaruhi *switching intention* Pegawai Negeri Sipil (PNS) dalam beralih dari *traditional learning* ke *online learning* dengan menggunakan kerangka *Push Pull Mooring (PPM)*. Penelitian ini melibatkan 463 responden PNS yang pernah menggunakan kedua metode pembelajaran dan dianalisis menggunakan metode Structural Equation Modeling (SEM) dengan bantuan SPSS dan AMOS. Hasil penelitian menunjukkan bahwa faktor penarik (*pull factor*) secara keseluruhan memiliki pengaruh signifikan terhadap keinginan berpindah, sedangkan tidak semua faktor pendorong (*push factor*) dan faktor penambat (*mooring factor*) memberikan pengaruh yang signifikan terhadap *switching intention*. Secara lebih rinci, variabel dalam *pull factor* seperti *task-technology fit*, *perceived usefulness*, dan *perceived enjoyment* berperan penting dalam mendorong peralihan ke *online learning*. Sementara itu, pada *push factor*, variabel seperti *perceived security risk*, *learning convenience*, dan *service quality* tidak seluruhnya menunjukkan pengaruh yang signifikan. Pada *mooring factor*, variabel seperti *switching cost*

dan *perceived innovativeness* memiliki peran sebagai faktor penahan yang dapat memengaruhi keputusan pengguna untuk tetap bertahan atau beralih. Temuan ini menunjukkan bahwa faktor daya tarik teknologi dan manfaat yang dirasakan menjadi determinan utama dalam mendorong adopsi *online learning*. Oleh karena itu, penelitian ini memberikan dasar empiris bahwa variabel dalam *pull factor* memiliki peran yang lebih dominan dibandingkan *push* dan *mooring factor* dalam menjelaskan perilaku perpindahan pengguna pada konteks pembelajaran digital [14].

Chang dan Chiu meneliti faktor-faktor yang memengaruhi *switching intention* dan retensi pengguna layanan *over-the-top* (OTT) di Taiwan menggunakan PPM. Penelitian tersebut menemukan bahwa *attractiveness of alternatives* secara konsisten merupakan *pull factor* yang paling signifikan. *Switching costs* dan kebiasaan (*habit*) terbukti sebagai *mooring factor* yang memoderasi perilaku perpindahan pengguna. Temuan ini mengkonfirmasi konsistensi peran *Alternative Attractiveness* sebagai prediktor utama *switching intention* di berbagai konteks platform digital [12].

Lisana melakukan penelitian penelitian tentang faktor-faktor yang memengaruhi *switching intention* mahasiswa di Indonesia terhadap platform *mobile learning* berbasis PPM dengan melibatkan 616 responden. Penelitian yang menggunakan SEM dengan perangkat AMOS ini menemukan bahwa faktor *push* (kenyamanan belajar), *pull* (otonomi dan kesenangan belajar), dan *mooring* (inovativitas mahasiswa) secara signifikan memengaruhi *switching intention*. Penelitian ini menjadi bukti bahwa kerangka PPM relevan dan dapat diterapkan pada konteks mahasiswa di Indonesia, sehingga menjadi referensi penting untuk penelitian yang diusulkan [13].

Fan dkk. meneliti pengaruh *information overload* dan *communication overload* terhadap perilaku *switching* platform *social commerce* di Malaysia. Penelitian dengan 477 responden ini menemukan bahwa kedua jenis *overload* memengaruhi *switching intention* secara tidak langsung melalui *online fatigue*. Temuan penting lainnya adalah *switching costs* terbukti memoderasi hubungan antara *switching intention* dan *switching behavior*, mempertegas peran *switching costs* sebagai *mooring factor* yang krusial dalam penelitian ini [15].

Lee dkk. melakukan penelitian untuk menganalisis perpindahan konsumen dari *platform e-commerce* domestik ke *cross-border e-commerce* (CBEC). Penelitian ini menggunakan pendekatan mixed-method dengan analisis *Partial Least Squares* (PLS) terhadap 727 responden. Hasil penelitian menunjukkan bahwa faktor pendorong seperti persepsi harga tinggi pada platform domestik, faktor penarik seperti keunikan produk dan reputasi platform, serta faktor penambat seperti *perceived behavioral control* dan *variety seeking* secara signifikan mempengaruhi *switching intention*. Selain itu, faktor *mooring* juga terbukti memoderasi hubungan antara *push* dan *pull* terhadap *switching intention* [16].

Sekarputri dkk. menguji peran privasi, keamanan, dan ketidakpuasan terhadap *switching intention* pengguna aplikasi pesan di Indonesia menggunakan PLS-SEM. Penelitian ini menemukan bahwa *privacy risk* dan *security risk* secara signifikan memengaruhi *dissatisfaction*, yang selanjutnya mendorong *switching intention*. Penelitian ini memiliki relevansi tinggi karena memvalidasi jalur kausal *privacy risk* → *dissatisfaction* → *switching intention* dalam konteks platform digital di Indonesia [17].

Kim dkk. (2024) melakukan penelitian empiris terhadap 446 pengguna ChatGPT di Korea Selatan menggunakan *Structural Equation Modeling* (SEM) untuk menguji faktor-faktor yang membentuk *user experience* chatbot AI generatif. Hasil penelitian menunjukkan bahwa *perceived usability* ($\beta = 0{,}254$, $p < 0{,}001$) dan *perceived enjoyment* ($\beta = 0{,}438$, $p < 0{,}001$) berpengaruh positif dan signifikan terhadap kepuasan pengguna, di mana dimensi hedonis (*enjoyment*) terbukti lebih dominan dibandingkan dimensi teknis. Lebih lanjut, kepuasan dan *perceived attachment* ($\beta = 0{,}447$ dan $\beta = 0{,}405$, $p < 0{,}001$) secara signifikan membentuk niat melanjutkan penggunaan platform AI generatif, yang mengindikasikan bahwa *user experience* yang positif membangun keterikatan emosional jangka panjang antara pengguna dan platform. Temuan ini memberikan validasi empiris terhadap peran *user experience* sebagai mediator antara *pull factors* dan *switching intention* dalam model Extended PPM yang diusulkan yaitu semakin tinggi kualitas *user experience* pada platform AI

generatif alternatif, semakin kuat pula niat pengguna untuk berpindah ke platform tersebut [18].

Pan dkk. meneliti *switching intention* mahasiswa bahasa Inggris sebagai bahasa asing (*English as a Foreign Language*/EFL) di Tiongkok dalam beralih dari metode pembelajaran kosakata tradisional ke aplikasi pembelajaran kosakata bahasa Inggris berbasis gamifikasi (*Gamified English Vocabulary Applications*/GEVA) menggunakan kerangka PPM. Dengan menggunakan metode PLS-SEM terhadap 639 mahasiswa penuh waktu dari tiga universitas di Provinsi Hubei, penelitian ini mengidentifikasi *push factors* berupa ketidaknyamanan belajar (*learning inconvenience*) dan *dissatisfaction* terhadap metode tradisional, *pull factors* berupa *perceived usefulness*, *learning autonomy*, dan *perceived enjoyment* dari aplikasi GEVA, serta *mooring factors* berupa *switching costs* dan kebiasaan (*habit*). Seluruh faktor tersebut terbukti berpengaruh signifikan terhadap *switching intention*. Lebih lanjut, *mooring factors* juga ditemukan berperan sebagai variabel moderasi yang memperkuat hubungan antara *push factors* dan *switching intention*. Penelitian ini memberikan bukti empiris tambahan bahwa *mooring factors* tidak hanya berfungsi sebagai penghambat perpindahan secara langsung, tetapi juga memodulasi kekuatan *push factors* dalam mendorong *switching intention* temuan yang relevan untuk memahami peran moderasi *Switching Costs* dalam model penelitian ini [19].

Widyaningrum dkk. menganalisis penerapan IS Success Model DeLone & McLean terhadap kepuasan pengguna *Learning Management System* (LMS) di Indonesia menggunakan SEM dengan AMOS. Penelitian ini menemukan bahwa *System Quality* dan *Information Quality* secara signifikan memengaruhi kepuasan pengguna pada platform LMS. Temuan ini memperkuat relevansi IS Success Model sebagai kerangka evaluasi kualitas platform digital dan menjadi landasan integrasi *System Quality* dan *Information Quality* sebagai *push factor* dalam model penelitian ini [20].

Tabel 2. 1 Perbandingan Studi Sebelumnya

No	Peneliti	Tahun	Tujuan	Metode	Hasil	Lokasi
1.	Zhou and Li (2024)	2024	Menguji *switching intention* pengguna antar platform AI generative menggunakan kerangka PPM.	SEM + fsQCA	Faktor pendorong (*push*), penarik (*pull*), dan penambat (*mooring*) berpengaruh signifikan terhadap *switching intention*. Faktor pendorong seperti ketidakpuasan dan persepsi harga mendorong pengguna untuk berpindah, sedangkan faktor penarik seperti keunikan produk dan reputasi platform meningkatkan daya tarik alternatif. Selain itu, faktor penambat seperti *perceived behavioral control* dan *variety seeking* juga berpengaruh signifikan serta memoderasi hubungan antara *push* dan *pull* terhadap *switching intention*.	Tiongkok
2.	Jo and Park	2023	Menganalisis *switching intention* pengguna sistem ERP dengan model PPM dengan fokus pada *information quality*.	Kuantitatif, PLS-SEM	*Information quality* berpengaruh signifikan dalam penelitian ini yang berarti faktor PPM mempengaruhi *switching intention*	Korea Selatan
3.	Susanti dkk.	2025	Menganalisis faktor-faktor yang memengaruhi *switching intention* PNS dari *traditional*	Kuantitatif, Structural Equation Modeling (SEM)	*Pull factor* berpengaruh signifikan terhadap *switching intention*, sedangkan *push* dan *mooring factor* tidak seluruhnya berpengaruh signifikan.	Indonesia

			learning ke *online learning* menggunakan kerangka PPM	dengan SPSS dan AMOS		
4.	Chang and Chiu	2023	Meneliti faktor yang memengaruhi *switching intention* dan retensi pengguna layanan OTT menggunakan PPM.	SEM	*Alternative attractiveness* secara konsisten merupakan *pull factor* paling signifikan. *Switching costs* dan habit memoderasi perilaku perpindahan pengguna OTT.	Taiwan
5.	Lisana	2023	Mengidentifikasi faktor yang memengaruhi *switching intention* mahasiswa di Indonesia terhadap *platform mobile learning* berbasis PPM.	SEM (AMOS)	*Push*, *pull*, dan *mooring* terbukti signifikan. Moderasi pengalaman memengaruhi dua jalur kausal. Memvalidasi relevansi PPM pada konteks mahasiswa di Indonesia.	Indonesia(mahasiswa)
6.	Fan dkk.	2024	Mengkaji pengaruh *information overload* dan *communication overload* terhadap perilaku *switching platform social commerce*.	SEM	*Information* dan *communication overload* memengaruhi *switching intention* melalui *online fatigue*. *Switching costs* memoderasi hubungan *switching intention → switching behavior*.	Malaysia (social commerce)
7.	Lee dkk.	2026	Menganalisis *switching intention* dari *e-commerce*	Mixed-method, PLS-SEM	*Push*, *pull*, dan *mooring* berpengaruh signifikan; *mooring* memoderasi hubungan terhadap *switching intention*	China (pengguna e-commerce)

			domestik ke CBEC dengan model PPM			
8.	Sekarputri d kk.	2024	Menguji peran privasi, keamanan, dan ketidakpuasan terhadap *switching intention* pada aplikasi messenger.	PLS-SEM	*Privacy risk* dan security risk secara signifikan memengaruhi *dissatisfaction* pengguna aplikasi pesan di Indonesia, yang selanjutnya mendorong *switching intention*.	Indonesia (messenger apps)
9.	Kim dkk.	2024	Meneliti faktor-faktor yang meningkatkan *user experience* pada chatbot AI generatif.	SEM	*Perceived interactivity* dan *perceived personalization* signifikan meningkatkan *user experience* chatbot AI generatif. Perceived anthropomorphism bervariasi tergantung konteks penggunaan.	Korea Selatan (AI chatbot)
10.	Widyaningrum dkk	2024	Menganalisis pengaruh IS Success Model DeLone & McLean terhadap kepuasan pengguna LMS di Indonesia.	SEM (AMOS)	*System Quality* dan *Information Quality* secara signifikan memengaruhi user satisfaction pada LMS Indonesia. Memperkuat relevansi IS Success Model sebagai kerangka evaluasi kualitas platform digital.	Indonesia (LMS)

2.2. Dasar Teori

2.2.1. Platform AI Generatif

Kecerdasan buatan (*Artificial Intelligence*/AI) saat ini telah menjadi salah satu teknologi yang paling berkembang pesat dan menarik perhatian secara global, termasuk di Indonesia. Penerapan AI dalam berbagai aspek kehidupan dipandang sebagai solusi untuk menjawab kebutuhan masyarakat modern. Kehadiran teknologi ini mendorong terciptanya beragam inovasi yang semakin maju dan kreatif, serta memberikan pengaruh signifikan pada berbagai sektor, seperti sosial, bisnis, ekonomi, hingga Kesehatan [21].

Implementasi AI di berbagai bidang diyakini mampu memberikan manfaat positif karena dapat membantu menyelesaikan berbagai permasalahan yang dihadapi manusia saat ini. Namun demikian, di balik manfaat tersebut, AI juga menimbulkan kekhawatiran, terutama terkait potensi tergantikannya peran tenaga kerja manusia oleh teknologi. Seiring dengan pesatnya perkembangan AI di masa depan, berbagai inovasi baru diperkirakan akan terus bermunculan. Oleh karena itu, masyarakat dituntut untuk terus mengembangkan kreativitas dan kemampuan diri agar tetap relevan dengan kemajuan teknologi, karena aspek tersebut masih menjadi keunggulan yang sulit digantikan oleh AI [21].

Platform AI Generatif (*Generative Artificial Intelligence*, GenAI) merujuk pada sistem berbasis kecerdasan buatan yang mampu menghasilkan konten baru dan orisinal mencakup teks, kode program, audio, maupun video berdasarkan instruksi masukan (prompt) yang diberikan pengguna [22]. Berbeda dengan sistem AI tradisional yang bersifat *discriminative* (mengklasifikasikan atau memprediksi berdasarkan data yang ada), platform AI generative beroperasi dengan cara mempelajari pola distribusi data melalui *deep generative models* dan mensintesis output baru yang belum pernah ada sebelumnya [23]. Kemapuan generatif ini dimungkinkan oleh arsitektur model seperti *Generative Adversarial Networks* (GANs), *Variational Autoencoders* (VAEs), dan yang paling dominan saat ini adalah *Large Language Models* (LLMs) berbasis arsitektur transformer yang mendasari sistem seperti GPT-4 (ChatGPT), Gemini, Claude, dan Copilot [24].

Definisi komprehensif GenAI dikemukakan oleh Banh and Strobel (2023) dalam jurnal *Electronic Markets* yang menyatakan bahwa AI generatif mampu menghasilkan konten baru dan realistis dalam spektrum yang luas (teks, gambar, kode program) berdasarkan basic user prompts dengan memanfaatkan *deep generative models* [23]. Selanjutnya, Dwivedi dkk. (2025) dalam *Information Systems Frontiers* mendefinisikan GenAI sebagai sistem AI yang mampu memproduksi konten seperti teks, gambar, music, kode program, dan output kreatif kompleks lainnya, yang didorong oleh kemajuan pesat *Large Languange Models* (LLMs) dengan kemampuan memahami dan menghasilkan bahasa manusia secara kontekstual [24].

Dari perspektif platform digital, Cusumano (2023 dalam *Communications of the ACM* menegaskan bahwa AI generatif merepresentasikan *a new innovation* platform yang secara fundamental mengubah cara nilai diciptakan dan didistribusikan di ekosistem digital [25]. Karakteristik utama yang membedakan platform AI generatif dari sistem *digital konvensional* meliputi yaitu kemampuan *autonomous content generation* yang dapat menghasilkan output berkualitas tinggi tanpa template tertentu, kapabilitas *multimodel processing* yang memungkinkan pemrosesan input dan output dalam berbagai format sekaligus, mekanisme *Reinforcement Learning from Human Feedback* (RLHF) untuk penyesuaian output berdasarkan preferensi pengguna, serta kemampuan *contextual understanding* yang memungkinkan sistem mempertahankan konteks percakapan secara berkesinambungan[23][24].

Dari sisi arsitektur teknis, platform AI generatif berbasis teks yang menjadi focus penelitian ini adalah ChatGPT (OpenAI), (Gemini DeepMind), Microsoft Copilot, DeepSeek, Claude (Anthropic) dan platform AI lainnya yang dibangun di atas fondasi *Large Language Models* (LLMs) yang dilatih pada korpus data teks berskala massif [24]. Model-model ini menggunakan pendekatan *pre-training* pada data besar dilanjutkan dengan *fine-tuning* yang lebih spesifik, sehingga mampu menghasilkan respons yang akurat, relevan, dan kontekstual terhadap berbagai jenis pertanyaan dan instruksi pengguna. Namun demikian, keterbatasan inheren dari arsitektur ini adalah potensi terjadinya *information hallucination,* yang fenomena di mana model menghasilkan Informasi yang tidak

akurat atau *factual* namun disajikan dengan tingkat keyakinan tinggi yang menjadi salah *push factor* utama dalam model penelitian ini [4].

Dalam konteks penggunaan mahasiswa di Indonesia, platform AI generatif berbasis teks berfungsi sebagai asisten akademik multifungsi yang dimanfaatkan untuk penulisan esai dan karya ilmiah, pemecahan soal matematika dan sains, pencarian Informasi, pemrograman komputer, terjemahan bahasa, serta pembuatan ringkasan materi kuliah. Tingginya adopsi ini mencapai 95% di kalangan mahasiswa di Indonesia berdasarkan *Global Student Survey Chegg* menempatkan platform AI generatif sebagai infrastruktur pembelajaran digital yang krusial, sekaligus menciptakan ekosistem kompetitif yang mendorong fenomena *switching intention* yang menjadi fokus penelitian ini [6].

2.2.2. Teori *Push-Pull-Mooring* (PPM)

Teori *Push–Pull–Mooring* (PPM) merupakan kerangka teoritis yang banyak digunakan untuk menjelaskan perilaku perpindahan (*switching behavior*) individu dari satu layanan, produk, atau platform ke alternatif lainnya. Teori ini berawal dari kajian migrasi yang dikemukakan oleh Lee (1966), yang menjelaskan bahwa keputusan berpindah dipengaruhi oleh faktor pendorong dari daerah asal, faktor penarik dari daerah tujuan, serta berbagai hambatan atau kondisi pribadi yang memengaruhi keputusan tersebut [26][27]. Konsep ini kemudian diadaptasi oleh Bansal, Taylor, dan St. James (2005) ke dalam konteks pemasaran jasa untuk menjelaskan perpindahan pelanggan antar penyedia layanan. Dalam perkembangannya, teori PPM semakin luas digunakan dalam penelitian sistem informasi karena mampu menjelaskan keputusan perpindahan pengguna secara lebih komprehensif, tidak hanya berdasarkan ketidakpuasan terhadap layanan lama, tetapi juga karena adanya daya tarik dari layanan alternatif dan adanya faktor penghambat atau pemudah perpindahan [28][29][27]. Pada konteks platform AI generatif, teori ini relevan karena pengguna sering kali membandingkan kualitas platform yang sedang digunakan dengan platform lain yang tersedia di pasar.

Secara konseptual, PPM terdiri atas tiga kelompok faktor utama, yaitu *push factors*, *pull factors*, dan *mooring factors*. *Push factors* adalah kondisi negatif yang berasal dari platform yang sedang digunakan sehingga mendorong pengguna untuk meninggalkannya, seperti ketidakpuasan, rendahnya kualitas sistem, rendahnya kualitas informasi, risiko privasi, atau pengalaman penggunaan yang buruk [27]. Dalam penelitian ini, *push factors* diwujudkan melalui *Information Hallucination*, *Privacy Risk*, *System Quality*, dan *Information Quality* yang memengaruhi *Dissatisfaction* sebelum akhirnya mendorong *Switching Intention*. *Pull factors* adalah faktor positif yang dimiliki platform alternatif sehingga menarik pengguna untuk berpindah, misalnya interaktivitas yang lebih baik, kemampuan menyerupai manusia, personalisasi yang lebih tinggi, serta daya tarik platform lain secara keseluruhan. Dalam penelitian ini, *pull factors* terdiri atas *Perceived Interactivity*, *Perceived Anthropomorphism*, *Perceived Personalization*, dan *Alternative Attractiveness*, dengan tiga variabel pertama membentuk *User Experience*. Adapun *mooring factors* adalah faktor yang menahan atau mempermudah perpindahan, seperti biaya berpindah, kebiasaan, loyalitas, atau pengalaman sebelumnya. Dalam konteks ini, *Switching Costs* menjadi faktor penting karena semakin tinggi biaya yang dirasakan pengguna untuk berpindah, semakin kecil kemungkinan mereka benar-benar meninggalkan platform yang sedang digunakan.

Keunggulan teori PPM terletak pada kemampuannya menjelaskan perilaku perpindahan secara lebih menyeluruh dibandingkan model adopsi teknologi seperti TAM, UTAUT, atau TPB yang lebih berfokus pada penerimaan awal terhadap Teknologi [30][27]. PPM tidak hanya melihat mengapa pengguna tertarik pada teknologi baru, tetapi juga mengapa mereka meninggalkan teknologi yang sudah digunakan, serta bagaimana hambatan perpindahan memengaruhi keputusan tersebut. Dengan demikian, keputusan berpindah tidak dipahami sebagai akibat dari satu faktor tunggal, melainkan sebagai hasil interaksi antara pengalaman negatif terhadap platform lama, daya tarik platform alternatif, dan besarnya hambatan untuk berpindah. Dalam praktiknya, pengguna dapat saja merasa tidak puas dan melihat platform lain lebih menarik, tetapi tetap bertahan apabila biaya belajar, waktu adaptasi, atau risiko

kehilangan kenyamanan dianggap terlalu besar. Karena itu, PPM memberikan penjelasan yang lebih realistis terhadap perilaku pengguna di lingkungan digital yang sangat kompetitif.

Teori PPM dipilih sebagai landasan utama penelitian ini karena sesuai dengan tujuan penelitian, yaitu menjelaskan faktor-faktor yang memengaruhi *Switching Intention* pengguna platform AI generatif di Indonesia. Persaingan antara ChatGPT, Gemini, Claude, Microsoft Copilot, DeepSeek, dan platform AI lainnya membuat pengguna memiliki banyak alternatif untuk memenuhi kebutuhan akademik maupun pekerjaan, sehingga perilaku perpindahan menjadi fenomena yang penting untuk dikaji. Penelitian ini menggunakan kerangka *extended PPM* dengan mengintegrasikan dua variabel dari *IS Success Model*, yaitu *System Quality* dan *Information Quality*, ke dalam *push factors* karena keduanya sangat menentukan kepuasan pengguna terhadap platform AI generatif. Selain itu, penelitian ini juga menambahkan *Alternative Attractiveness* sebagai *pull factor* langsung berdasarkan temuan Jo dan Park (2023), yang menunjukkan bahwa variabel tersebut merupakan salah satu prediktor kuat terhadap *Switching Intention* [9]. Dengan demikian, model penelitian ini mencakup *push factors* berupa *Information Hallucination*, *Privacy Risk*, *System Quality*, dan *Information Quality*; *pull factors* berupa *Perceived Interactivity*, *Perceived Anthropomorphism*, *Perceived Personalization*, dan *Alternative Attractiveness*; serta *mooring factor* berupa *Switching Costs*, sehingga diharapkan mampu memberikan penjelasan yang lebih lengkap mengenai niat perpindahan pengguna platform AI generatif.

2.2.3. *IS Success* Model DeLone dan McLean

IS Success Model atau Model Keberhasilan Sistem Informasi yang dikembangkan oleh DeLone dan McLean merupakan salah satu teori yang paling banyak digunakan dalam bidang Sistem Informasi untuk mengevaluasi keberhasilan implementasi suatu sistem informasi. Model ini pertama kali diperkenalkan oleh DeLone dan McLean pada tahun 1992 sebagai upaya untuk menyatukan berbagai ukuran keberhasilan sistem informasi yang pada saat itu masih digunakan secara terpisah oleh para peneliti [31]. Menurut DeLone dan

McLean (1992), keberhasilan suatu sistem informasi tidak dapat dinilai hanya berdasarkan aspek teknis atau tingkat penggunaan sistem semata, tetapi harus dipahami sebagai suatu proses yang melibatkan hubungan antara kualitas sistem, kualitas informasi, penggunaan sistem, kepuasan pengguna, serta manfaat yang dihasilkan bagi individu maupun organisasi. Oleh karena itu, model ini menjadi salah satu kerangka evaluasi yang paling komprehensif karena mampu menjelaskan bagaimana suatu sistem informasi memberikan nilai tambah kepada penggunanya [32][31].

Seiring dengan perkembangan teknologi informasi, khususnya internet dan sistem berbasis layanan (*service-based information systems*), DeLone dan McLean melakukan penyempurnaan terhadap model yang mereka kembangkan. Pada tahun 2003, mereka memperbarui model tersebut dengan menambahkan dimensi Service Quality, menggabungkan dimensi Individual Impact dan Organizational Impact menjadi Net Benefits, serta memperjelas hubungan timbal balik antara penggunaan sistem (*Use/Intention to Use*) dan kepuasan pengguna (*User Satisfaction*). Penyempurnaan tersebut dilakukan karena perkembangan sistem informasi modern tidak lagi hanya berorientasi pada kualitas perangkat lunak, tetapi juga pada kualitas layanan yang diberikan kepada pengguna. Model revisi ini kemudian menjadi model yang paling banyak digunakan dalam penelitian Sistem Informasi karena dinilai lebih sesuai dengan perkembangan teknologi digital dan berbagai jenis platform berbasis internet [32].

Menurut DeLone dan McLean (2003), keberhasilan suatu sistem informasi dipengaruhi oleh enam dimensi utama, yaitu *System Quality*, *Information Quality*, Service Quality, Use/Intention to Use, User Satisfaction, dan Net Benefits. Keenam dimensi tersebut saling berhubungan membentuk suatu proses evaluasi yang menjelaskan bahwa kualitas sistem, kualitas informasi, dan kualitas layanan akan memengaruhi tingkat penggunaan sistem serta kepuasan pengguna. Selanjutnya, penggunaan sistem dan kepuasan pengguna akan menghasilkan manfaat bagi individu maupun organisasi. Hubungan tersebut menunjukkan bahwa keberhasilan sistem informasi bukan hanya ditentukan oleh kemampuan teknologi yang dimiliki, tetapi juga oleh bagaimana sistem tersebut

mampu memberikan pengalaman penggunaan yang baik serta menghasilkan informasi yang berkualitas [32][31].

Dalam penelitian ini, tidak seluruh dimensi pada *IS Success Model* digunakan. Penelitian hanya mengadopsi dua konstruk utama, yaitu *System Quality* dan *Information Quality*, karena kedua variabel tersebut memiliki keterkaitan yang paling kuat dengan karakteristik platform AI generatif. Pemilihan kedua variabel ini juga didukung oleh penelitian Mengikuti pendekatan yang telah divalidasi oleh Jo dan Park serta Zhou [9][11], penelitian ini mengintegrasikan dua dimensi *IS Success Model system quality* dan *information quality* sebagai *push factor* berbasis kualitas teknis ke dalam model PPM, sementara dimensi lain seperti *service quality* tidak dilibatkan karena platform AI generatif berbasis teks tidak melibatkan interaksi layanan personal sebagaimana konteks asli model ini dirumuskan.

2.2.4. Status Quo Bias Theory (SQBT)

Selain kerangka PPM dan *IS Success Model*, penelitian ini turut menggunakan Teori *Status Quo Bias* (*Status Quo Bias Theory*/SQBT) sebagai landasan pendukung untuk menjelaskan mekanisme kerja *mooring factor*. Teori ini pertama kali dirumuskan oleh Samuelson dan Zeckhauser (1988) yang melalui serangkaian eksperimen pengambilan keputusan membuktikan bahwa individu secara sistematis cenderung mempertahankan kondisi yang sedang berjalan (*status quo*), yakni memilih untuk tidak melakukan apa pun atau mempertahankan keputusan sebelumnya, meskipun tersedia alternatif yang secara objektif lebih baik [33]. Kecenderungan tersebut bersumber dari tiga kelompok penjelasan, yaitu pengambilan keputusan rasional berbasis perbandingan biaya dan manfaat perpindahan (*net benefits of change*), kesalahan persepsi kognitif berupa *loss aversion*, serta komitmen psikologis terhadap pilihan sebelumnya seperti kebiasaan (*habit*) dan inersia (*inertia*) [33].

Dalam ranah sistem informasi, Kim dan Kankanhalli (2009) mengadaptasi SQBT untuk menjelaskan resistensi pengguna terhadap implementasi sistem informasi baru. Hasil penelitian mereka menempatkan *switching costs* sebagai konstruk sentral yang meningkatkan resistensi pengguna, sekaligus menunjukkan

bahwa keputusan bertahan atau berpindah merupakan hasil evaluasi rasional antara nilai *status quo* dan nilai yang ditawarkan alternatif (*perceived value of change*) [34]. Nugawela dan Sedera (2022) melalui tinjauan literatur atas penerapan SQBT pada konteks adopsi dan keberlanjutan penggunaan sistem informasi juga menegaskan bahwa *status quo bias* tidak bekerja sebagai penghambat absolut, melainkan sebagai kondisi yang memengaruhi bagaimana pengguna menimbang perbandingan antara kondisi saat ini dan alternatif yang tersedia [35].

Relevansi SQBT bagi penelitian ini terletak pada kemampuannya melengkapi kerangka PPM dalam menjelaskan peran *Switching Costs*. Kerangka PPM klasik memposisikan *mooring factor* semata-mata sebagai penghambat yang memperlemah pengaruh *push factor* dan *pull factor* terhadap *switching intention*. SQBT memberikan penjelasan yang lebih rinci, yaitu bahwa ketika pengguna menanggung biaya perpindahan yang tinggi, pengguna tidak berhenti mengevaluasi alternatif, melainkan menaikkan ambang bukti yang dibutuhkan sebelum bersedia berpindah. Konsekuensinya, ketika alternatif dinilai cukup unggul untuk melampaui ambang tersebut, evaluasi terhadap alternatif justru dapat berperan lebih kuat, bukan lebih lemah, dalam membentuk niat berpindah [33][34]. Dengan demikian, SQBT digunakan dalam penelitian ini bukan sebagai kerangka utama, melainkan sebagai landasan teori pendukung yang menjadi dasar intepretasi hasil pengujian efek moderasi *Switching Costs* (H6 dan H7). Landasan ini diperlukan karena arah efek moderasi *mooring factor* pada konteks layanan digital yang dapat diakses secara gratis tidak selalu sesuai dengan asumsi pelemahan sebagaimana diprediksi kerangka PPM klasik.

2.3. Pengembangan Hipotesis dan Model

Bagian ini memaparkan dasar pembentukan 13 hipotesis penelitian secara sistematis. Setiap hipotesis didasarkan pada temuan empiris dari studi-studi terdahulu yang telah dikaji pada bagian 2.1 dan 2.2, serta diturunkan dari kerangka PPM yang diperluas dengan variabel *System Quality*, *Information Quality*, dan *Alternative Attractiveness*.

2.3.1. Pengaruh *Information Hallucination* terhadap *Dissatisfaction* (H1a)

Information hallucination merujuk pada fenomena ketika platform AI generatif menghasilkan konten yang tidak akurat, tidak faktual, atau sepenuhnya dibuat-buat, namun disajikan dengan kepercayaan diri tinggi seolah-olah benar. Rawte dkk. mengklarifikasikan fenomena ini ke dalam tiga kategori yaitu factual hallucination (pernyataan yang bertentangan dengan fakta terverifikasi), faithfulness hallucination (keluaran yang tidak setia pada konteks atau instruksi pengguna), dan reasoning hallucination (kesalahan penalaran logis meskipun premisnya benar) [36]. Dalam konteks pengguna akademik, persepsi terhadap ketidakakuratan Informasi yang dihasilkan platform AI secara langsung berpotensi menimbulkan ketidakpuasan, mengingat ekspetasi akurasi Informasi pada konteks akademis tergolong sangat tinggi [37].

Zhou dan Li (2024) membuktikan secara empiris bahwa *information hallucination* berpengaruh positif dan signifikan terhadap *dissatisfaction* pengguna platform AI generatif ((β = 0,284, p < 0,001) [4]. Temuan ini konsisten dengan literatur kepercayaan konsumen digital yang menunjukkan bahwa ketidakakuratan Informasi merupakan salah satu pemicu utama ketidakpuasan pengguna sistem Informasi [9]. Ketika pengguna mahasiswa menemukan bahwa output platform AI yang mereka gunakan tidak dapat diandalkan untuk keperluan akademis, kepercayaan mereka menurun tajam dan memicu evaluasi ulang terhadap platform tersebut [37]. Berdasarkan uraian di atas, maka hipotesis pertama dirumuskan sebagai berikut:

H1a: *Information Hallucination* berpengaruh positif dan signifikan terhadap *Dissatisfaction* pengguna platform AI generatif.

2.3.2. Pengaruh *Privacy Risk* terhadap *Dissatisfaction* (H1b)

Privacy risk merujuk pada persepsi pengguna terhadap potensi kerugian yang timbul dari pengumpulan, penyimpanan, pemrosesan, atau penyalahgunaan data pribadi oleh platform AI generatif yang digunakan. Karena platform AI generatif secara inheren menyimpan riwayat percakapan, preferensi, dan data perilaku pengguna untuk meningkatkan kualitas responsnya, muncul kekhawatiran mengenai siapa yang dapat mengakses data tersebut, bagaimana

data digunakan, dan apakah data dapat dibagikan kepada pihak ketiga tanpa sepengetahuan pengguna. Kekhawatiran tersebut menjadi salah satu isu utama dalam adopsi AI generatif karena dapat menurunkan rasa aman dan kepercayaan pengguna terhadap platform [38].

Dalam konteks teori Push-Pull-Mooring (PPM), Zhou dan Li (2024) mengkonfirmasi bahwa *privacy risk* merupakan *push factor* dengan pengaruh terbesar terhadap *dissatisfaction* dalam model PPM platform AI generatif mereka ($\beta = 0{,}384$, $p < 0{,}001$). Semakin tinggi persepsi risiko privasi yang dirasakan pengguna, semakin besar kemungkinan pengguna merasa tidak puas dan mempertimbangkan untuk beralih ke platform AI generatif lain yang dianggap lebih aman [4]. Sekarputri dkk. (2024) juga memvalidasi jalur kausal ini dalam konteks aplikasi digital di Indonesia, menemukan bahwa *privacy risk* berpengaruh signifikan terhadap *dissatisfaction* yang selanjutnya mendorong *switching intention* [17]. Berdasarkan temuan tersebut, maka hipotesis kedua dirumuskan sebagai berikut:

H1b: *Privacy Risk* berpengaruh positif dan signifikan terhadap *Dissatisfaction* pengguna platform AI generatif.

2.3.3. Pengaruh *System Quality* terhadap *Dissatisfaction* (H1c)

System quality mengacu pada penilaian pengguna terhadap karakteristik teknis dan fungsional dari sistem AI yang digunakan. Merujuk pada IS Success Model DeLone dan McLean (1992; 2003), dimensi *system quality* mencakup beberapa indikator utama yaitu keandalan sistem (reliability), kecepatan respons (response time), kemudahan pengguna (ease of use), serta fleksibilitas (flexibility) [31]. Dalam konteks platform AI generatif, rendahnya *system quality* seperti respons yang lambat, sistem yang sering mengalami gangguan, atau antarmuka yang sulit dipahami akan menimbulkan ketidakpuasan yang mendorong pengguna untuk mencari platform alternatif [9].

Jo dan Park (2023) membuktikan bahwa *system quality* berpengaruh signifikan terhadap kepuasan pengguna sistem IS ($p < 0{,}001$) dalam kerangka PPM [9]. Widyaningrum dkk. (2024) mengkonfirmasi hal yang sama dalam konteks Indonesia, di mana *system quality* terbukti mempengaruhi kepuasan

pengguna platform LMS [20]. Zhou (2016) secara khusus memposisikan *system quality* sebagai *push factor* utama dalam kerangka PPM perpindahan pengguna platform utama dalam kerangka PPM perpindahan pengguna platform digital [11]. Berdasarkan uraian tersebut, hipotesis ketiga dirumuskan sebagai berikut:

H1c: *System Quality* yang rendah berpengaruh positif dan signifikan terhadap *Dissatisfaction* pengguna platform AI generatif.

2.3.4. Pengaruh *Information Quality* terhadap *Dissatisfaction* (H1d)

Information Quality merujuk pada penilaian pengguna terhadap kualitas output atau Informasi yang dihasilkan oleh platform AI generatif. Dimensi ini mecakup lima aspek utama berdasarkan IS Success Model yaitu akurasi (accuracy) adalah kebenaran Informasi yang dihasilkan, relevansi (relevance) adalah kesesuain Informasi dengan kebutuhan pengguna, kelengkapan (completeness) yaitu tingkat ketercakupan Informasi, konsistensi (consistency) adalah kesamaan Informasi yang dihasilkan dari waktu ke waktu, serta ketepatan waktu (timeliness) adalah kemutakhiran informasi yang disajikan [31][20].

Information Quality merupakan *push factor* yang sangat krusial dalam konteks platform AI generatif. Ketika platform menghasilkan output yang tidak akurat, tidak relevan, atau tidak lengkap, pengguna akan mengalami ketidakpuasan yang signifikan. Jo dan Park (2023) menemukan *information quality* merupakan antesedan kepuasan pengguna yang paling dominan dalam model PPM mereka bahkan lebih dominan dari *system quality* [9]. Widyaningrum dkk (2024) juga mengkonfirmasi pengaruh signifikan *information quality* terhadap kepuasan pengguna platform digital di Indonesia [20]. Berdasarkan uraian tersebut, hipotesis keempat dirumuskan sebagai berikut:

H1d: *Information Quality* yang rendah berpengaruh positif dan signifikan terhadap *Dissatisfaction* pengguna platform AI generatif.

2.3.5. Pengaruh *Dissatisfaction* terhadap *Switching Intention* (H2)

Dissatisfaction adalah kondisi afektif negatif yang dialami pengguna ketika kinerja aktual platform gagal memenuhi ekspetasi mereka. Berbeda dengan satisfaction yang berfungsi sebagai hambatan perpindahan,

dissatisfaction berfungsi sebagai katalis yang mendorong pengguna untuk secara aktif mempertimbangkan perpindahan platform lain [27]. Dalam kerangka PPM, *dissatisfaction* berperan sebagai mediator antara *push factor* (*information hallucination*, *privacy risk*, rendahnya *system quality*, dan rendahnya *information quality*) dan *switching intention* [4].

Zhou dan Li (2024) membuktikan bahwa *dissatisfaction* berpengaruh positif signifikan terhadap *switching intention* pengguna platform AI generatif (β = 0,289, p < 0,001) [4]. Lebih jauh, analisis fsQCA dalam penelitian tersebut menemukan bahwa *dissatisfaction* merupakan core condition yang paling konsisten dalam memicu *switching intention*, artinya tanpa *dissatisfaction* faktor-faktor lain tidak cukup kuat untuk mendorong perpindah pengguna. Sekarputri dkk. (2024) juga mengkonfirmasi peran *dissatisfaction* sebagai medtator antara *privacy risk* dan *switching intention* dalam konteks platform digital di Indonesia [17]. Berdasarkan uraian tersebut, hipotesis kelima dirumuskan sebagai berikut:

H2: *Dissatisfaction berpengaruh positif dan signifikan terhadap Switching Intention pengguna platform AI generatif.*

2.3.6. Pengaruh *Perceived Interactivity* terhadap *User Experience* (H3a)

Perceived interactivity mengacu pada persepsi pengguna terhadap kualitas, kedalaman, dan keterlibatan interaksi dua arah antara pengguna dengan platform AI generatif. Konstruk ini mencakup tiga dimensi utama yaitu mutual communication yang artinya kemampuan platform untuk mempertahankan konteks percakapan secara berkesinambungan, responsiveness yang artinya kecepatan dan ketepatan platform dalam merespons setiap masukan pengguna, serta perceived control yang artinya tingkat kendali yang dirasakan pengguna dalam mengarahkan alur interakksi dengan platform [39]. Semakin tinggi interactivity, semakin positif *user experience* yang dirasakan pengguna [4].

Zhou dan Li (2024) membuktikan bahwa *perceived interactivity* berpengaruh positif signifikan terhadap *user experience* pengguna platform AI generatif (β = 0,301, p < 0,001) [4]. Kim dkk. (2024) mengkonfirmasi temuan ini dalam konteks chatbot AI generatif di Korea Selatan, menemukan bahwa *perceived interactivity* merupakah salah satu faktor yang paling dominan dalam

membentuk *user experience* [18]. Dalam penelitian ini, *perceived interactivity* berfungsi sebagai *pull factor* yang mencerminkan kualitas interaksi pada platform AI generatif alternatif yang menarik pengguna untuk pindah. Berdasarkan uraian tersebut, hipotesis keenam dirumuskan sebagai berikut:

H3a: *Perceived Interactivity* berpengaruh positif dan signifikan terhadap *User Experience* pada platform AI generatif alternatif.

2.3.7. Pengaruh *Perceived Anthropomorphism* terhadap *User Experience* (H3b)

Perceived anthropomorphism merujuk pada kecenderungan pengguna untuk mempersepsikan sifat-sifat kemanusiaan pada platform AI generatif, seperti kemampuan berempati, kepribadian yang konsisten, gaya bahasa yang natural dan hangat, serta kemampuan untuk memahami nuansa emosional dalam percakapan. Meski atribusi sifat manusia pada entitas non-manusia ini merupakan respons kognitif alami yang dapat memperkaya pengalaman interaksi, anthropomorfisme yang berlebihan berpotensi menimbulkan efek *uncanny valley* yang justru menggangu kenyamanan pengguna [40].

Efek *perceived anthropomorphism* terhadap *user experience* masih menunjukkan hasil yang beragam dalam literatur. Zhou dan Li (2024) menemukan bahwa *perceived anthropomorphism* tidak berpengaruh signifikan terhadap *user experience* pada konteks pengguna Tiongkok [4]. Di sisi lain, Kim dkk. (2024) menemukan bahwa efek *perceived anthropomorphism* bervariasi tergantung pada jenis platform dan karakteristik pengguna [18]. Perbedaan hasil ini dapat disebabkan oleh perbedaan budaya dan norma sosial antar negara. Penelitian ini tetap memasukkan variabel ini untuk menguji konsistensinya pada konteks mahasiswa di Indonesia yang memiliki karakteristik budaya yang berbeda dari pengguna Tiongkok. Berdasarkan uraian tersebut, hipotesis ketujuh dirumuskan sebagai berikut:

H3b: *Perceived Anthropomorphism* berpengaruh positif dan signifikan terhadap *User Experience* pada platform AI generatif alternatif.

2.3.8. Pengaruh *Perceived Personalization* terhadap *User Experience* (H3c)

Perceived personalization mengacu pada tingkat persepsi pengguna bahwa platform AI generatif mampu menyesuaikan respons, rekomendasi, dan pengalaman interaksi secara individual berdasarkan kebutuhan, preferensi, dan konteks spesifik pengguna tersebut. Personalisasi pada platform AI generatif dapat terwujud melalui berbagai mekanisme, seperti kemampuan platform untuk mengingat konteks percakapan sebelumnya, menyesuaikan gaya komunikasi dengan preferensi pengguna, memberikan rekomendasi yang relevan dengan kebutuhan akademik pengguna, serta menghasilkan *output* yang disesuaikan dengan tingkat pemahaman dan latar belakang pengguna [41].

Perceived personalization yang tinggi meningkatkan relevansi output platform bagi pengguna dan memperkuat keterkaitan emosional pengguna terhadap platform tersebut, sehingga berfungsi sebagai *pull factor* yang menarik pengguna menuju platform alternatif yang menawarkan pengalaman yang lebih personal. Zhou dan Li (2024) membuktikan bahwa *perceived personalization* berpengaruh positif signifikan terhadap *user experience* ($\beta = 0{,}279$, $p < 0{,}001$) [4]. Kim dkk. (2024) mengkonfirmasi bahwa personalisasi merupakan salah satu faktor terpenting dalam meningkatkan *user experience* pada chatbot AI generatif [18]. Berdasarkan uraian tersebut, hipotesis kedelapan dirumuskan sebagai berikut:

H3c: *Perceived Personalization* berpengaruh positif dan signifikan terhadap *User Experience* pada platform AI generatif alternatif.

2.3.9. Pengaruh *User Experience* terhadap *Switching Intention* (H4)

User experience dapat diartikan sebagai keseluruhan penilaian subjektif pengguna terhadap kualitas, kenyamanan, kepuasan, dan nilai yang diperoleh dari interaksi dengan suatu platform. Konstruk ini bersifat multidimensional, mencakup dimensi utilitarian (seberapa efektif platform membantu penyesuaian tugas) maupun dimensi hedonis (seberapa menyenangkan proses interaksi dengan platform) [18]. Dalam kerangka PPM penelitian ini, *user experience* berperan sebagai mediator antara tiga *pull factor* anteseden (*perceived interactivity, perceived anthropomorphism, perceived personalization*) dengan *switching intention.*

Semakin positif *user experience* yang dirasakan pengguna pada platform AI alternatif dibandingkan platform yang sedang digunakan, semakin tinggi pula niat mereka untuk berpindah. Zhou dan Li (2024) membuktikan bahwa *user experience* berpengaruh positif signifikan terhadap *switching intention* (β = 0,320, p < 0,001) [4]. Berdasarkan uraian tersebut, hipotesis kesembilan dirumuskan sebagai berikut:

H4: *User Experience* berpengaruh positif dan signifikan terhadap *Switching Intention* pengguna platform AI generatif.

2.3.10. Pengaruh Langsung *Alternative Attractiveness* terhadap *Switching Intention* (H5)

Alternative Attractiveness didefinisikan sebagai penilaian keseluruhan pengguna mengenai seberapa menarik, menguntungkan, dan superior platform AI generatif alternatif dibandingkan platform yang sedang mereka gunakan. Bansal dkk. mendefiniskan *attractiveness of alternatives* sebagai ketersediaan layanan alternatif yang menarik perhatian pelanggan, apabila pesaing dinilai lebih menarik dan memuaskan konsumen cenderung berpindah [27]. Konsep ini diperkuat oleh Krishnan dan Raghuram, yang dalam tinjauan sistematis terhadap literatur push-pull-mooring menjelaskan bahwa alternative attractiveness mencerminkan persepsi konsumen terhadap ketersediaan produk atau layanan pesaing yang dinilai lebih unggul, sehingga daya tarik dari layanan pesaing tersebut dapat mendorong konsumen untuk berpindah dari penyedia layanan yang sedang digunakan [42].

Alternative Attractiveness berperan sebagai *pull factor* langsung yang mendorong *switching intention*, berbeda dari *user experience* yang merupakan *pull factor* termediasi. Jo dan Park (2023) menemukan bahwa *alternative attractiveness* merupakan prediktor terkuat *switching intention* dalam model PPM mereka (β = 0,709, p < 0,001) jauh melampaui pengaruh *dissatisfaction* [9]. Chang dan Chiu (2023) secara konsisten mengkonfirmasi peran dominan *alternative attractiveness* sebagai prediktor *switching intention* pada konteks layanan OTT di Taiwan [12]. Ketiadaan variabel ini dalam model Zhou dan Li

menjadi salah satu gap penelitian utama yang dijawab oleh penelitian ini. Berdasarkan uraian tersebut, hipotesis kesepuluh dirumuskan sebagai berikut:

H5: *Alternative Attractiveness berpengaruh positif dan signifikan secara langsung terhadap Switching Intention pengguna platform AI generatif.*

2.3.11. Efek Moderasi *Switching Cost* pada Hubungan *Dissatisfaction* → *Switching Intention* (H6)

*Switching cost*s dalam penelitian ini didefinisikan sebagai persepsi usaha (*effort*) yang harus ditanggung pengguna Ketika mempertimbangkan perpindahan dari platform AI generatif yang sedang digunakan ke platform alternatif, mencakup kerepotan, waktu, dan tenaga adaptaasi ke platform baru. Dimensi biaya finansial tidak menjadi fokus pengukuran karena platform yang diteliti umumnya dapat diakses secara gratis. Adapun biaya-biaya ini dapat dibedakan ke dalam tiga kategori utama yaitu *procedural switching costs* (waktu dan upaya mempelajari platform baru), *financial switching costs* (biaya moneter berlangganan platform baru), dan *relational switching costs* (biaya psikologis berupa rasa kehilangan kenyamanan dan kebiasaan) [4].

Dalam kerangka PPM, *switching cost*s berperan sebagai *mooring factor* yang menghambat perpindahan meskipun pengguna mengalami ketidakpuasan atau menemukan platform alternatif yang menarik. Zhou dan Li (2024) membuktikan bahwa *switching cost*s secara signifikan memoderasi hubungan *dissatisfaction* → *switching intention* ($\beta = -0{,}150$, $p < 0{,}01$) [4]. Artinya pengguna dengan persepsi *switching cost*s yang tinggi akan tetap bertahan pada platform yang ada meskipun tidak puas. Fan dkk. (2024) juga mengkonfirmasi peran moderasi *switching cost*s pada platform social commerce [15]. Secara konseptual, peran moderasi *switching costs* pada hubungan *dissatisfaction* dan *switching intention* dapat dijelaskan melalui perbedaan sifat ketidakpuasan yang dihadapi pengguna. Ketika ketidakpuasan bersumber dari kualitas fungsional platform yang dirasakan secara langsung, seperti akurasi jawaban atau stabilitas sistem, dorongan untuk mencari alternatif cenderung lebih kuat dibandingkan besarnya usaha yang dibutuhkan untuk berpindah, sehingga *switching costs* berpotensi tidak cukup kuat untuk menahan niat berpindah yang telah

terbentuk. Dengan kata lain, *switching costs* pada jalur ini diprediksi bekerja sebagai penghambat yang melemahkan pengaruh *dissatisfaction*, namun kekuatan efek ini bergantung pada seberapa dominan usaha adaptasi dibandingkan dengan tingkat ketidakpuasan yang dirasakan. Berdasarkan uraian tersebut, hipotesis kesebelas dirumuskan sebagai berikut:

H6: *Switching Cost*s memoderasi secara negatif hubungan antara *Dissatisfaction* dan *Switching Intention*; pengaruh *Dissatisfaction* terhadap *Switching Intention* lebih lemah Ketika *Switching Cost*s tinggi.

2.3.12. Efek Moderasi *Switching Cost*s pada Hubungan *User Experience* → *Switching Intention* (H7)

Selain memoderasi hubungan *dissatisfaction* terhadap *switching intention*, *switching costs* juga diprediksikan memoderasi hubungan antara *user experience* dan *switching intention*. Meskipun pengalaman positif dengan platform AI alternatif mendorong niat berpindah, tingginya *switching cost*s dapat melemahkan dampak tersebut dengan menimbulkan hambatan usaha (*effort)* ,procedural, finansial, dan relasional yang signifikan bagi pengguna [4].

Zhou dan Li (2024) membuktikan bahwa *switching cost*s secara signifikan memoderasi hubungan *user experience* → *switching intention* ($\beta = -0{,}128$, $p < 0{,}01$) [4]. Temuan ini mengindikasikan bahwa daya tarik *user experience* platform alternatif dilemahkan oleh tingginya *switching cost*s. Ini berarti pengguna dengan persepsi *switching cost*s yang tinggi akan cenderung tetap menggunakan platform lama meskipun platform alternatif memberikan *user experience* yang lebih baik. Secara konseptual, efek moderasi pada jalur ini diprediksi bekerja melalui mekanisme yang berbeda dari H6, karena *user experience* mencerminkan evaluasi terhadap kualitas platform alternatif, bukan evaluasi terhadap platform yang sedang digunakan. Ketika *switching costs* tinggi, pengguna berada dalam kondisi terikat pada *status quo* sehingga daya tarik pengalaman platform alternatif perlu melampaui ambang tertentu sebelum benar-benar mengubah niat berpindah; sebaliknya, pada tingkat *switching costs* yang rendah, sedikit peningkatan *user experience* pada platform alternatif berpotensi cukup untuk mendorong niat berpindah. Prediksi arah pelemahan (negatif) pada H7

didasarkan pada logika bahwa hambatan usaha berpindah akan meredam pengaruh pengalaman positif tersebut; kemungkinan arah sebaliknya turut dipertimbangkan mengingat *switching costs* juga dapat berfungsi sebagai penanda intensitas keterikatan pengguna pada *status quo*, sebagaimana dijelaskan melalui *Status Quo Bias Theory*. Berdasarkan uraian tersebut, hipotesis kedua belas dirumuskan sebagai berikut:

H7: *Switching Cost*s memoderasi secara negatif hubungan antara *User Experience* dan *Switching Intention*; pengaruh *User Experience* terhadap *Switching Intention* lebih lemah Ketika *Switching Cost*s tinggi.

2.3.13. Pengaruh Langsung *Switching Cost*s terhadap *Switching Intention* (H8)

Selain berperan sebagai moderator, *switching costs* juga memiliki pengaruh langsung negatif terhadap *switching intention*. Semakin tinggi persepsi usaha yang harus ditanggung untuk berpindah platform baik berupa waktu adaptasi, kerepotan mempelajari fitur baru, kehilangan riwayat percakapan, maupun biaya finansial berlangganan platform baru semakin rendah niat pengguna untuk melakukan perpindahan, terlepas dari tingkat kepuasan atau ketidakpuasan mereka [4][11].

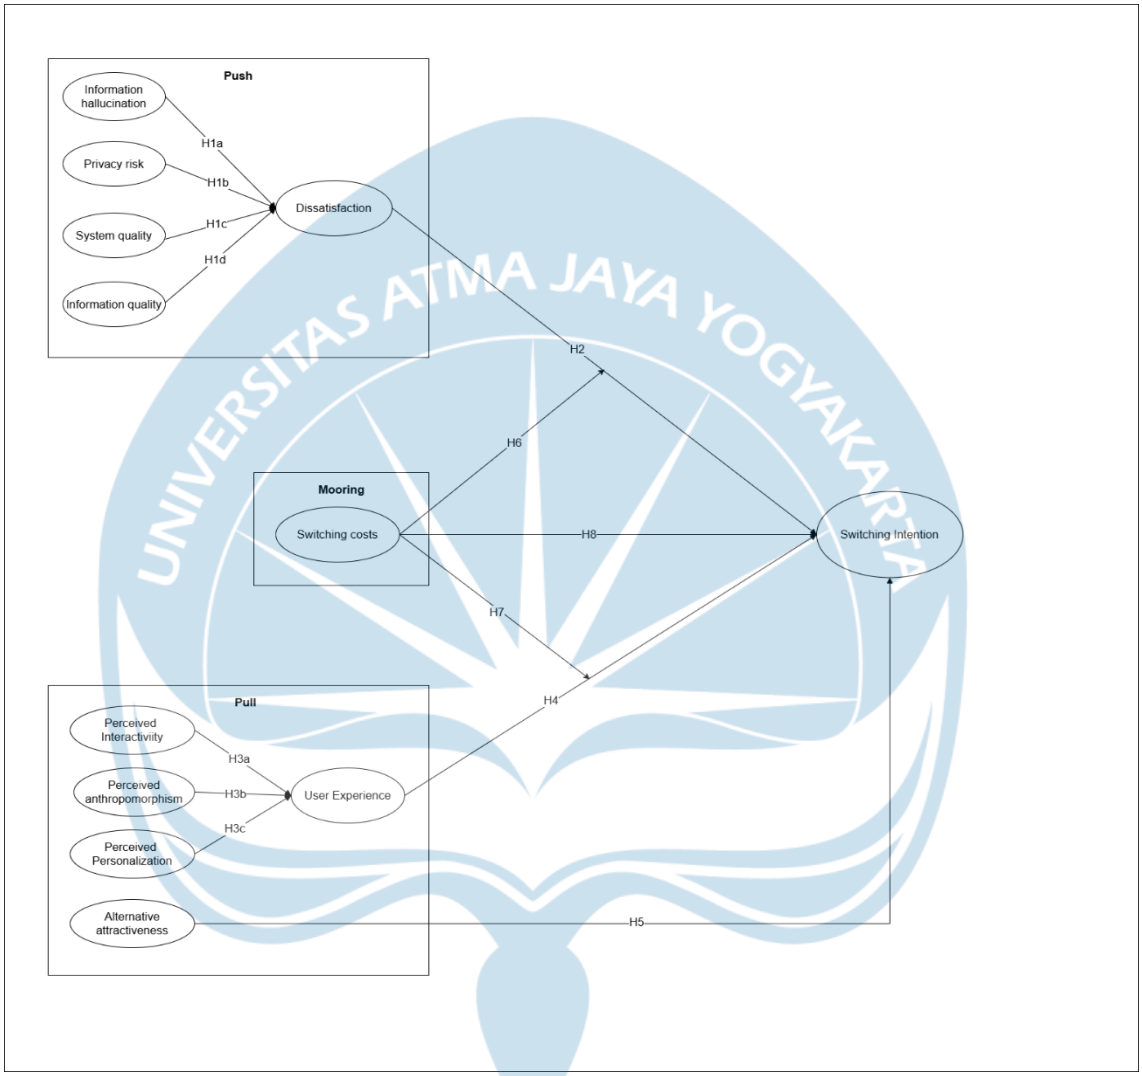
Zhou dan Li (2024) membuktikan pengaruh negatif langsung *switching costs* terhadap *switching intention* ($\beta = -0{,}375$, $p < 0{,}001$), menjadikan *switching costs* sebagai *mooring factor* dengan pengaruh terbesar dalam model aslinya [4]. Fan dkk. (2024) mengkonfirmasi temuan ini dalam konteks platform social commerce di Malaysia, menemukan bahwa *switching cost*s memoderasi hubungan *switching intention* dan switching behavior [15]. Berdasarkan uraian tersebut, hipotesis ketiga belas dirumuskan sebagai berikut:

H8: *Switching Cost*s berpengaruh negatif dan signifikan secara langsung terhadap *Switching Intention* pengguna platform AI generatif.

2.3.14. Model Penelitian

Model penelitian ini dikembangkan berdasarkan model konseptual Extended *Push-Pull-Mooring* (PPM) yang mengintegrasikan variabel-variabel dari tiga kerangka teoritis utama yaitu teori *Push-Pull-Mooring* yang pertama kali diadaptasi oleh Bansal et

al. (2005) ke dalam konteks perilaku konsumen [42], mengintegrasikan variabel IS Success Model DeLone dan McLean (2003) sebagai fondasi *push factor*s berbasis kualitas teknis [31], dan kerangka *user experience* platform AI generatif yang dikembangkan oleh Zhou dan Li (2024) [4]. Model Konseptual yang diusulkan ditunjukkan pada Gambar 2.1



Gambar 2. 1 Model Penelitian oleh Penulis

Model dalam penelitian ini menguji faktor-faktor yang mempengaruhi niat beralih (*Switching Intention*) pengguna platform AI generatif berbasis teks di Indonesia melalui tiga kelompok variabel yang bekerja secara simultan, yaitu *push factor*s, *pull factor*s, dan *mooring factor*. Model ini merupakan perluasan (extension) dari model Zhou dan Li (2024) dengan tiga kontribusi utama yaitu penambahan *System Quality* dan *Information Quality* dari IS Success Model sebagai *push factor*s berbasis kualitas teknis, penambahan *Alternative Attractiveness* sebagai *pull factor* langsung terhadap *Switching*

Intention, dan pengujian peran ganda *Switching Cost*s baik sebagai pengaruh langsung maupun moderator [4].

Secara keseluruhan, model penelitian ini terdiri dari 12 variabel laten dan 13 jalur hipotesis yang mencakup hubungan langsung, tidak langsung melalui mediator, dan efek moderasi. Variabel-variabel dalam model dikelompokkan menjadi *push factor*s (*Information Hallucination*, *Privacy Risk*, *System Quality, Information Quality*) yang secara bersama-sama mempengaruhi *Dissatisfaction*; *pull factor*s (*Perceived Interactivity*, Perceived Anthropomorphism, *Perceived Personalization* yang mempengaruhi *User Experience*, serta *Alternative Attractiveness* yang berpengaruh langsung); dan *mooring factor* (*Switching Cost*s) yang berperan sebagai penghambat perpindahan secara langsung sekaligu memoderasi hubungan *Dissatisfaction* dan *User Experience* terhadap *Switching Intention*.