

Personalização de Interfaces Adaptativas Baseada em Análise de Dados do Usuário: uma Revisão Sistemática

João Vitor D. Silva¹ Eunice P. S. Nunes² Patrícia C. de Souza³
Cristiano Maciel⁴ Luciana C. L. F. Borges⁵

¹Instituto de Computação – Universidade Federal de Mato Grosso (UFMT)
Cuiabá – MT – Brazil

jvdantasilva@hotmail.com, eunice.nunes@ic.ufmt.br,
patricia.souza@ufmt.br, crismac@gmail.com,
lucianafariaborges@gmail.com

Abstract. Introduction: Adaptive interfaces that personalize based on user data analysis have gained prominence as essential solutions for improving user experience in digital systems. **Objective:** This study aims to conduct a systematic review to identify personalization techniques, challenges, and trends in adaptive interface development. **Methodology or Steps:** A systematic review was conducted analyzing 46 studies published between 2018-2024, following established protocols for literature review. **Results:** The analysis revealed predominant use of artificial intelligence techniques, emphasis on behavioral data collection and explicit preferences, with challenges including model complexity and need for high-quality data. Despite obstacles, there is growing scientific interest driven by potential to enhance user experience and accommodate diverse profiles.

Keywords Adaptive Interfaces, Personalization, User Data, Artificial Intelligence, Usability.

Resumo. Introdução: Interfaces adaptativas que personalizam com base na análise de dados dos usuários têm ganhado destaque como soluções essenciais para melhorar a experiência do usuário em sistemas digitais. **Objetivo:** Este estudo visa conduzir uma revisão sistemática para identificar técnicas de personalização, desafios e tendências no desenvolvimento de interfaces adaptativas. **Metodologia ou Etapas:** Foi realizada uma revisão sistemática analisando 46 estudos publicados entre 2018-2024, seguindo protocolos estabelecidos para revisão de literatura. **Resultados:** A análise revelou uso predominante de técnicas de inteligência artificial, ênfase na coleta de dados comportamentais e preferências explícitas, com desafios incluindo complexidade dos modelos e necessidade de dados de qualidade. Apesar dos obstáculos, observa-se crescente interesse científico impulsionado pelo potencial de aprimorar a experiência do usuário e atender perfis diversos.

Palavras-Chave Interfaces adaptativas, Personalização, Dados do usuário, Inteligência artificial, Usabilidade.

1. Introdução

O avanço das tecnologias digitais e a crescente ubiquidade de dispositivos conectados têm impulsionado a geração massiva de dados provenientes de interações humanas

em ambientes virtuais e físicos. Estima-se que, com o uso intensivo de plataformas sociais, dispositivos móveis e sensores de Internet das Coisas (IoT), volumes substanciais de dados sobre comportamentos, preferências e contextos de uso estejam disponíveis para análise e personalização de serviços [ElSayed et al. 2024]. Nesse contexto, ganha relevância o desenvolvimento de interfaces que sejam capazes de utilizar esses dados de maneira inteligente para moldar a experiência do usuário. Tais interfaces, fundamentadas em mecanismos de adaptação e aprendizado, visam atender a um espectro diversificado de usuários, incluindo pessoas com deficiências, idosos e indivíduos com diferentes níveis de familiaridade tecnológica, promovendo a chamada usabilidade universal [Miraz et al. 2021].

Apesar dos avanços, a personalização de interfaces ainda enfrenta desafios. A implementação de interfaces adaptativas depende da coleta e análise de grandes volumes de dados pessoais, o que levanta preocupações com privacidade, segurança e confiabilidade das informações. Além disso, a literatura aponta que a adaptação automática pode gerar inconsistências no design, exigindo que os usuários lidem com interfaces que mudam frequentemente, o que pode impactar negativamente a usabilidade e aumentar a carga cognitiva [Okopnyi et al. 2024]. Outro obstáculo é a dificuldade em criar modelos precisos de preferência e comportamento dos usuários com base em conjuntos de dados limitados ou incompletos, especialmente em ambientes móveis e dinâmicos [ElSayed et al. 2024]. Esses desafios mostram que, embora a personalização baseada em análise de dados prometa experiências mais contextualizadas, ainda há lacunas no entendimento de como aplicá-la de forma eficaz, equitativa e sustentável.

Salienta-se que este estudo está alinhado aos Grandes Desafios de Interação Humano-Computador (IHC) [Pereira et al. 2024], propostos pela Comissão Especial de Interação Humano-Computador (CEIHC) para o período de 2025 a 2035, com ênfase no GC7: Interação com Tecnologias Emergentes – Um Ecossistema que Integra Humanos, Tecnologias e Contextos [Zaina et al. 2024]. O desafio reconhece a crescente integração entre tecnologias emergentes — como Inteligência Artificial, análise de dados e interfaces adaptativas — e os contextos sociotécnicos em que os usuários estão inseridos. Nesse cenário, a personalização de interfaces adaptativas baseada na análise de dados do usuário representa uma resposta concreta às demandas desse ecossistema complexo, promovendo interações mais contextuais, responsivas e centradas no ser humano. Ao investigar como dados comportamentais têm sido utilizados para ajustar interfaces dinamicamente, este estudo contribui para o avanço do conhecimento técnico e metodológico necessário para o desenvolvimento de tecnologias mais sensíveis ao contexto, inclusivas e adaptáveis, em consonância com as diretrizes de pesquisa e inovação propostas no GC7.

Nesse cenário, justifica-se a realização de uma revisão sistemática que investigue de que forma os dados de uso dos usuários têm sido empregados na implementação de interfaces adaptativas, bem como quais tipos de dados comportamentais são mais relevantes para esse processo. A sistematização desse conhecimento é essencial para, de um lado, revelar como estudos anteriores utilizaram dados de interação dos usuários para criar sistemas de interface adaptativa e, de outro, identificar as categorias de dados mais relevantes, como padrões de navegação, tempo de interação e preferências, que orientam o desenvolvimento de interfaces adaptativas. Ao consolidar evidências de diferentes estudos, esta pesquisa busca fornecer subsídios teóricos e práticos para pesquisadores

e desenvolvedores interessados em aprimorar a usabilidade e acessibilidade por meio de interfaces que se adaptem de maneira transparente às necessidades individuais e contextuais.

Logo, o objetivo geral deste artigo é identificar os tipos de dados dos usuários que são fundamentais para a coleta, os métodos mais comuns de análise e as abordagens de adaptação de interface que personalizam e otimizam a experiência do usuário. Este artigo tem como objetivos específicos: (1) identificar como os dados dos usuários têm sido utilizados na implementação de interfaces adaptativas e (2) determinar quais tipos de dados são mais relevantes nesse contexto. Esses objetivos visam preencher a lacuna existente na literatura e fornecer subsídios para o avanço desta área de pesquisa, destacando práticas bem-sucedidas e propondo diretrizes para futuras implementações.

A pesquisa conduzida neste estudo caracteriza-se como uma revisão sistemática da literatura (RSL), fundamentada na metodologia Preferred Reporting Items for Systematic Review and Meta-Analysis (PRISMA), que assegura maior transparência e reprodutibilidade na seleção e análise dos estudos [Moher et al. 2010]. O enfoque adotado é predominantemente qualitativo, uma vez que a investigação busca compreender padrões, abordagens e estratégias de personalização de interfaces adaptativas com base na análise de dados de uso dos usuários. No entanto, aspectos quantitativos também são incorporados na avaliação da qualidade dos estudos revisados, permitindo uma classificação comparativa entre as publicações analisadas. A busca sistemática foi realizada em bases de dados relevantes, entre as quais se destacam o **IEEE Xplore Digital Library**, a **ACM Digital Library**, a **SpringerLink** e a **ScienceDirect**.

Para alcançar os objetivos propostos, o artigo foi estruturado em quatro seções. A introdução apresenta a contextualização, o problema, a justificativa e os objetivos do estudo. A metodologia detalha os critérios e processos adotados na revisão sistemática. A seção de resultados e discussões, sintetiza as principais descobertas obtidas e analisa os achados à luz do estado da arte. A conclusão traz uma reflexão sobre as implicações do estudo e sugere direções para pesquisas futuras.

2. Metodologia

Nesta seção, apresenta-se o percurso metodológico, abrangendo o planejamento da pesquisa, sua execução e a avaliação da qualidade, com destaque para o protocolo adotado nesta RSL.

2.1. Planejamento

A metodologia PRISMA foi selecionada por oferecer um guia abrangente que aprimora a transparência e a reprodutibilidade nas revisões sistemáticas. Conforme destacado por [Moher et al. 2010], suas diretrizes ajudam a identificar boas práticas e lacunas na literatura, garantindo uma análise estruturada e consistente. O objetivo principal desta RSL foi investigar como os dados dos usuários têm sido utilizados na implementação de interfaces adaptativas, bem como determinar quais tipos de dados são mais relevantes nesse contexto. Esse enfoque busca compreender as estratégias mais eficazes e as tecnologias emergentes que contribuem para o desenvolvimento de interfaces personalizadas e alinhadas às necessidades dos usuários.

Durante as etapas iniciais, para a definição da string de busca, foram selecionados termos relacionados a interfaces adaptativas e comportamento do usuário como base. Termos como "adaptive user interface", "dynamic user interface" e "personalized interface" foram escolhidos para contemplar diferentes variações de nomenclatura. Além disso, expressões relacionadas a dados de uso e padrões de interação, como "user behavior" e "behavioral patterns", foram incluídas para ampliar a captação de estudos focados em adaptação baseada em dados.

Ao longo do processo de refinamento, os termos selecionados foram testados em diferentes combinações para otimizar os resultados. Assim, os termos finais para a string de busca foram estabelecidos conforme apresentado na Tabela 1.

Tabela 1. Termos e String de Busca

Termos	String de Busca
"adaptive user interface", "adaptive UI", "dynamic user interface", "personalized interface", "user data", "user behavior", "user interaction", "behavioral patterns"	("adaptive user interface"OR "adaptive UI"OR "dynamic user interface"OR "personalized interface") AND ("user data"OR "user behavior"OR "user interaction"OR "behavioral patterns")

As bases de dados selecionadas e suas respectivas justificativas estão apresentadas na Tabela 2.

Tabela 2. Bases de Dados e Justificativas

Bases de Dados	Justificativa
ACM Digital Library	Base de dados especializada em computação
IEEE Xplore	Base de dados voltada para engenharia, eletrônica, computação e tecnologias emergentes
Elsevier (ScienceDirect)	Base de dados interdisciplinar que abrangem computação
Springer Link	Base de dados com forte presença nas áreas de ciência e tecnologia

Para este trabalho foram propostas duas questões de pesquisa. Essas questões podem ser lidas na Tabela 3, juntamente com suas respectivas motivações.

Tabela 3. Questões de Pesquisa e Motivações

Questões de Pesquisa	Motivações
QP1: Como os dados de uso dos usuários têm sido utilizados para implementar interfaces adaptativas?	Revelar como estudos anteriores utilizaram dados de interação dos usuários para criar sistemas de interface adaptativa.
QP2: Quais tipos de dados de uso dos usuários são mais relevantes para a implementação de AUI (Adaptive User Interfaces)?	Identificar e classificar as categorias de dados do usuário que são mais significativas para o desenvolvimento de interfaces adaptativas.

Na Tabela 4 estão listados os critérios de seleção pelos quais foram definidos os estudos incluídos da presente revisão.

Tabela 4. Critérios de Inclusão e Exclusão

Critérios de Inclusão	Critérios de Exclusão
Estudos publicados entre 2018 e 2024.	Estudos publicados fora do intervalo de 2018 a 2024.
Estudos relacionados ao tema da revisão e que contenham termos da string de busca no título ou resumo.	Estudos não relacionados ao tema da revisão ou que não contenham termos da string de busca no título ou resumo.
Estudos revisados por pares.	Estudos duplicados.
	Estudos com acesso restrito (paywall).

Para garantir a qualidade dos estudos primários incluídos nesta revisão, foi estabelecido um conjunto de critérios de avaliação conforme [Kitchenham et al. 2009]. A Tabela 5 apresenta as perguntas utilizadas nesse processo, permitindo uma análise objetiva dos estudos selecionados. Cada resposta foi categorizada em três níveis: sim, moderadamente e não e, recebeu pontuações de 1, 0,5 ou 0, respectivamente. Apenas os estudos que atingiram um mínimo de dois pontos foram considerados aptos para inclusão, assegurando um padrão de qualidade adequado à pesquisa.

Tabela 5. Questões de Avaliação

ID	Questão
QA1	Os objetivos exploram como dados do usuário podem personalizar interfaces adaptativas?
QA2	O contexto da pesquisa (tipo de usuários, domínio de aplicação) é claramente descrito?
QA3	O método de pesquisa inclui a coleta e análise de dados reais de usuários?
QA4	A análise dos dados do usuário (comportamento, interações) é realizada com rigor metodológico?
QA5	Os critérios de adaptação da interface são explicitamente vinculados aos dados do usuário?

2.2. Execução

A etapa de execução da revisão sistemática aconteceu em abril de 2025, momento em que a string de busca foi aplicada às bases de dados previamente selecionadas.

Os estudos recuperados, contendo título, resumo e informações bibliográficas, foram exportados das bases de origem e, posteriormente, importados para a ferramenta Parsifal (disponível em: <https://parsif.al>), utilizada para organização e análise dos dados no processo de revisão sistemática.

O Parsifal é uma plataforma online desenvolvida para apoiar pesquisadores na realização de revisões sistemáticas da literatura. Essa ferramenta permite que os pesquisadores, mesmo estando geograficamente dispersos, colaborem em um ambiente de trabalho compartilhado para a definição do protocolo e execução das diversas etapas da pesquisa. No contexto deste estudo, o uso do Parsifal facilitou a seleção e avaliação dos artigos pelos autores.

Dentro da plataforma, cada estudo foi analisado individualmente e classificado como aceito ou rejeitado com base nos critérios de inclusão e exclusão previamente estabelecidos. Além disso, o Parsifal contribuiu para a identificação e remoção de artigos duplicados, aumentando a precisão e a eficiência do processo de seleção.

Para a etapa de análise dos estudos incluídos, foi elaborado um formulário de extração de dados com os seguintes campos: 1) Referência do estudo, contendo as informações bibliográficas, como autores, título e fonte de publicação; 2) Data de extração, registrando o momento em que os dados foram coletados; 3) Tipo de interface utilizada, descrevendo a modalidade da interface empregada (ex.: web, mobile, realidade aumentada); 4) Dados coletados do usuário, referentes às informações obtidas diretamente dos participantes, como respostas, comportamentos, preferências ou padrões de interação; 5) Uso de inteligência artificial, indicando se o sistema incorpora técnicas de IA; 6) Atualização da interface em tempo real, verificando se ocorre adaptação imediata da interface com base nas ações do usuário; e 7) Refinamento ou aprendizado do sistema ao longo do tempo, analisando se o sistema é capaz de evoluir ou melhorar seu desempenho com base no uso contínuo ou na integração de novos dados.

O preenchimento desse formulário foi realizado por meio de uma planilha eletrônica, visando facilitar a visualização e o agrupamento das informações extraídas. Os dados obtidos nessa fase encontram-se sistematizados e descritos na seção de Resultados.

2.3. Avaliação de Qualidade

A avaliação de qualidade dos artigos em uma RSL assegura a inclusão de estudos relevantes e bem conduzidos, evitando que evidências inconsistentes comprometam as conclusões da revisão. A Figura 1 ilustra os resultados da avaliação da qualidade metodológica dos estudos incluídos na revisão.

A pontuação atribuída aos artigos variou de 2,0 a 5,0, sendo 5,0 o escore máximo possível segundo os critérios estabelecidos. Esses critérios foram definidos com base na pertinência dos estudos em relação ao objetivo da revisão, contemplando aspectos como a clareza do contexto da pesquisa, o rigor metodológico na coleta e análise de dados dos usuários, bem como a explicitação dos critérios de adaptação da interface vinculados aos dados coletados.

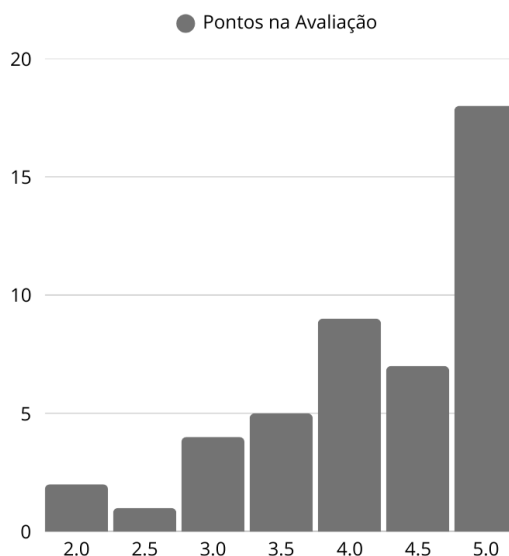


Figura 1. Notas de avaliação de qualidade.

Conforme apresentado na Figura 1, a maioria dos estudos avaliados obteve pontuação igual ou superior a 4,0, o que indica, de modo geral, um nível metodológico satisfatório a elevado. Esses resultados reforçam a confiabilidade das evidências sintetizadas e conferem maior robustez às conclusões extraídas ao longo da análise. A avaliação da qualidade metodológica foi aplicada aos 46 artigos incluídos na revisão sistemática. Como todos os estudos apresentaram pontuação superior a 2,0, nenhum foi excluído com base nesse critério.

3. Resultados e Discussões

Como resultado do processo de revisão sistemática, foi elaborado um fluxograma conforme as diretrizes PRISMA, apresentado na Figura 2. Inicialmente, foram identificados 1084 artigos por meio de buscas em bases de dados. Na primeira etapa do processo de triagem, foram excluídos 698 estudos com base no critério de ano de publicação. Em seguida, procedeu-se à remoção de duplicatas e à exclusão de artigos com acesso restrito. Por fim, realizou-se uma análise do conteúdo dos estudos restantes, com a verificação da aderência temática, bem como da presença de palavras-chave relevantes nos títulos e resumos. Esses critérios visaram garantir a relevância e a adequação dos artigos selecionados ao escopo da pesquisa.

Na Figura 3, é possível observar que a base que forneceu o maior número de estudos foi a Elsevier (ScienceDirect). Os estudos incluídos provenientes dessa base de dados representam 50% do total de estudos selecionados.

Com base na análise dos anos de publicação, foi gerada a Figura 4, que revela um crescimento no número de artigos publicados sobre o tema desta revisão entre 2022 e 2024, com um aumento de aproximadamente quatro vezes em relação aos anos anteriores. Antes desse período, observa-se uma tendência instável, marcada por oscilações no número de publicações ao longo dos anos.

A seguir as seções 3.1 e 3.2 apresentam cada questão de pesquisa acompanhada

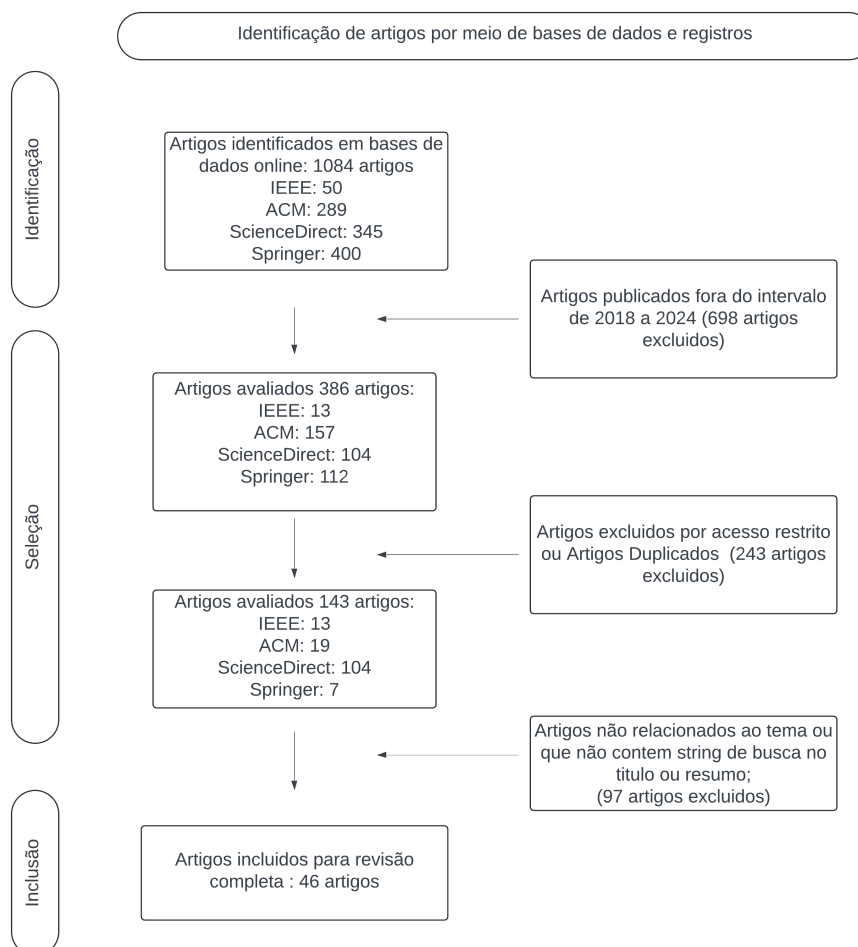


Figura 2. Fluxograma PRISMA

de uma breve análise dos artigos selecionados, destacando os principais achados para a questão endereçada.

3.1. QP1: Como os dados de uso dos usuários têm sido utilizados para implementar interfaces adaptativas?

Interfaces adaptativas são definidas como componentes dinâmicos capazes de modificar características e funcionalidades da interface com base nas necessidades do usuário [Carrera-Rivera et al. 2024]. Segundo os autores, esse comportamento adaptativo é mediado por mecanismos inteligentes, sendo comum o uso de técnicas de Inteligência Artificial, como sistemas de recomendação, processamento de linguagem natural e aprendizado de máquina para ajustar automaticamente um ou mais elementos da interface em tempo real.

Considerando isso, durante o processo de extração de dados da RSL, foram analisados os estudos que empregaram técnicas de inteligência artificial para a adaptação de interfaces de acordo com o contexto de uso. Os resultados dessa análise são apresentados na Figura 5.

A maioria dos artigos analisados, mais de 70%, utilizou-se de técnicas

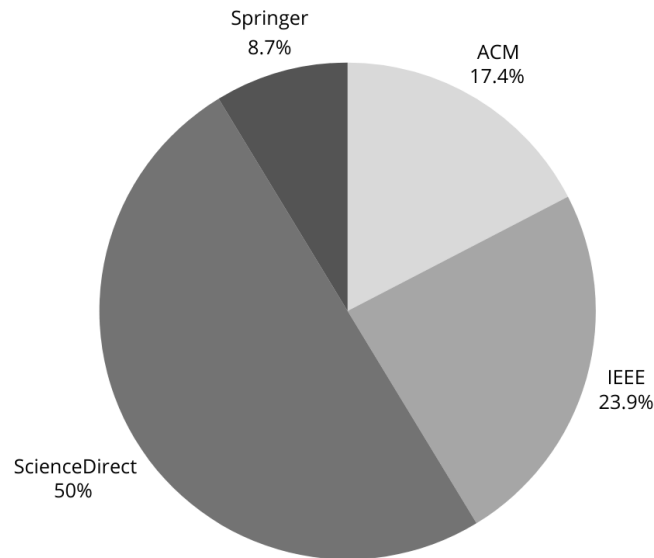


Figura 3. Bases de dados da RSL

diversificadas ou mesmo combinações de estratégias com o objetivo de promover adaptações mais eficazes e relevantes para seus usuários.

O estudo apresentado por [Rathnayake et al. 2019] ilustra a forma como a inteligência artificial foi utilizada de maneira integrada, conectando a análise de dados com a personalização da interface. Nesse estudo a coleta de dados foi realizada por meio de funções integradas às interfaces web, que capturavam as interações dos usuários com os componentes da interface. Essas informações foram utilizadas para gerar mapas de calor que indicavam a relevância de cada componente para o usuário em termos de uso e engajamento. Os dados coletados foram enviados ao servidor principal, onde foram armazenados e posteriormente analisados com técnicas de aprendizado de máquina, tais como agrupamento (k-means) e classificação (AdaBoost), permitindo identificar padrões comportamentais e agrupar os usuários em perfis semelhantes. A partir desses perfis, o sistema conseguiu personalizar dinamicamente as interfaces, ativando ou desativando componentes e reorganizando-os com base nas preferências inferidas, demonstrando uma aplicação integrada da inteligência artificial tanto na análise dos dados comportamentais quanto na adaptação efetiva da interface.

Em outros casos, a inteligência adaptativa não se fundamenta em técnicas computacionais, mas sim em regras contextualizadas conforme sua aplicação [Iglesias et al. 2018], [Zhang and Sundar 2019], [Yeroshkin and Sobecki 2024], [Finne et al. 2022], [Rei et al. 2024], [Wang et al. 2024b], [Akiki 2018], [Lu et al. 2024], [Gomi et al. 2023], [Khan and Khusro 2023].

No estudo de [Rei et al. 2024] seu principal objetivo é adaptar dinamicamente os objetivos diários de caminhada e as mensagens motivacionais com base no perfil psicológico e no desempenho anterior dos usuários. Essas adaptações são feitas utilizando regras pré-definidas e teorias motivacionais, como a Teoria da Autodeterminação (SDT) e a Teoria do Foco Regulatório (RFT), sem recorrer a técnicas avançadas de aprendizado de máquina ou mineração de dados. O sistema coleta informações iniciais, como nível




Figura 4. Análise dos anos de publicação

de atividade física, motivação e preferências regulatórias, por meio de questionários. Os níveis de atividade física são utilizados para definir metas diárias de passos ajustadas ao perfil individual de cada usuário, enquanto as preferências regulatórias orientam a seleção das mensagens motivacionais mais adequadas ao seu perfil psicológico. Assim, as regras contextuais mostram-se suficientes para a adaptação da interface, visando aumentar a motivação e o engajamento dos usuários ao longo do tempo.

Outro aspecto relevante diz respeito às estratégias de atualização de interfaces aplicadas nos estudos. A abordagem automática predominou, registrando 37 trabalhos, enquanto as demais categorias apresentaram uma representatividade significativamente reduzida, com apenas 1 trabalho para as estratégias manual, sem atualização e manual e automática, e 6 trabalhos para a semiautomática. Esse resultado ressalta a preferência por métodos automatizados, conforme ilustrado na Figura 6.

A aplicação descrita no estudo [Romero et al. 2020] está inserida no contexto de transporte urbano, especificamente no auxílio ao usuário no acesso a informações sobre horários de ônibus por meio de um aplicativo móvel adaptativo chamado Tiramisu. O objetivo da interface adaptativa é reduzir o esforço do usuário ao selecionar filtros, rolar telas e navegar pelo aplicativo, oferecendo uma experiência personalizada com base no comportamento anterior do usuário, como localização e horário. A adaptação em tempo real foi implementada por meio de técnicas de aprendizado de máquina que permitem ao sistema identificar padrões nas escolhas dos usuários e ajustar dinamicamente as rotas de ônibus exibidas, priorizando aquelas mais frequentemente utilizadas em determinado contexto. Os autores relataram que isso proporcionou ganhos significativos em usabilidade, especialmente para usuários com deficiência visual, pois reduziu o tempo e o esforço cognitivo necessários para encontrar as informações desejadas.

No contexto de adaptações semi automáticas, o sistema detecta necessidades



Figura 5. Uso de inteligência artificial segundo os estudos selecionados

adaptativas e oferece sugestões ao usuário, que pode aceitá-las ou rejeitá-las. Ou seja, o sistema toma parte da decisão, mas a ativação final depende do usuário. Na pesquisa de [Wu et al. 2024] é apresentada uma aplicação móvel voltada para apoiar o gerenciamento de doenças crônicas. O objetivo é personalizar a experiência do usuário com base em suas necessidades individuais, considerando fatores como gravidade da doença, capacidades cognitivas e preferências pessoais. A interface inicia com uma configuração padrão, mas oferece adaptações em tempo real com base em critérios como dados de saúde, comportamento do usuário e contexto de uso, essa abordagem foi escolhida após contribuições dos usuários, que indicou preocupações quanto à perda de controle sobre a interface caso as adaptações fossem totalmente automáticas.

O trabalho de [Finne et al. 2022], o único artigo no qual a adaptação do tipo manual foi observada, a atualização da interface ocorre por meio de um assistente guiado que permite ao usuário selecionar as funcionalidades desejadas. Esse mecanismo de seleção foi desenvolvido com base no conceito de Design Multicamadas Invertido (*Reversed Multi-Layer Design*), no qual a interface começa com todas as funcionalidades disponíveis e vai sendo simplificada conforme as necessidades e preferências do usuário. O foco do projeto está em empoderar o usuário idoso, oferecendo controle sobre as adaptações e evitando soluções adaptativas automáticas, que podem gerar sensação de perda de domínio sobre o sistema.

No trabalho de [Yera et al. 2019], embora não tenha sido implementada uma adaptação efetiva da interface, o estudo apresenta relevância para a área de interfaces adaptativas ao investigar padrões de interação de diferentes grupos de profissionais de saúde, principalmente farmacêuticos (usuários primários) e, secundariamente, médicos e enfermeiros, com um dashboard eletrônico de segurança medicamentosa no contexto da atenção primária. A partir da análise de dados de uso, como cliques e movimentos




Figura 6. Atualização em tempo real dos estudos selecionados

do mouse, foi possível identificar diferenças significativas nos níveis de engajamento, competência e comportamento entre os grupos de usuários. Os autores ressaltam que esses achados podem servir como base para o desenvolvimento de estratégias futuras de personalização da interface, ao evidenciar tanto a necessidade quanto o potencial dos sistemas adaptativos em responder às diferentes demandas dos diversos perfis de usuários em ambientes clínicos.

Outro estudo relevante que se aprofunda nessa discussão foi conduzido por [Zhang and Sundar 2019], e investiga como diferentes abordagens de personalização em sistemas de recomendação online influenciam a experiência do usuário, especialmente em relação à privacidade, à sensação de controle e à qualidade percebida das recomendações. Nesse estudo, foram comparadas duas estratégias principais: a personalização pró-ativa, na qual o sistema oferece conteúdos personalizados automaticamente, e a personalização reativa, em que o usuário precisa solicitar ativamente as recomendações. De acordo com os resultados apresentados por [Zhang and Sundar 2019], a personalização pró-ativa foi considerada mais útil e com maior qualidade nas sugestões, mas também esteve associada a níveis mais altos de preocupação com a privacidade. Já a personalização reativa proporcionou aos usuários uma sensação semelhante de controle sobre os dados, embora com uma percepção de qualidade inferior nas recomendações.

Outro ponto avaliado nos artigos refere-se ao refinamento da interface com base na captação de informações dos usuários. Conforme observado na Figura 7, a maioria dos estudos apresentou um processo de refinamento incremental, indicando uma evolução gradual e contínua das interfaces ao longo do tempo.

Um bom exemplo é o estudo de [Suryani et al. 2024], que utilizou técnicas de inteligência artificial para desenvolver interfaces adaptativas em sistemas de gestão de aprendizagem, com o objetivo de reduzir a carga cognitiva dos usuários e melhorar a



Figura 7. Refinamento da adaptação nos estudos selecionados

experiência de aprendizagem. O sistema integra dados coletados dos usuários, como motivação, conhecimento prévio e preferências de aprendizagem, e, com base nessas informações, é capaz de ajustar automaticamente a interface simplificando e sugerindo pausas estratégicas ou recomendando conteúdos mais alinhados ao estilo de aprendizagem individual. Dessa forma, o modelo se fundamenta em características cognitivas do usuário, criando um ambiente de aprendizagem mais personalizado .

Também foram encontrados 32.6% dos artigos que optaram por não realizarem refinamento. O estudo [Laguna Salvadó et al. 2022] exemplifica essa abordagem, apresentando um sistema de apoio à decisão voltado para auxiliar na escolha de tecnologias usadas em reformas de edifícios com o objetivo de torná-los mais eficientes energeticamente. O sistema permite que o arquiteto ou responsável pela decisão selecione os critérios como custo, impacto ambiental e conforto, e defina o peso e a precisão com que cada critério deve ser avaliado.

A motivação de [Laguna Salvadó et al. 2022] para não incluir mecanismos de aprendizado ao longo do tempo está no fato de que o foco do sistema é oferecer uma interface interativa e transparente, onde as mudanças feitas pelo usuário se reflitam imediatamente nos resultados. Dessa forma, o usuário pode explorar diferentes possibilidades e entender melhor o impacto de suas escolhas, sem depender de atualizações automáticas ou adaptações baseadas em decisões anteriores.

O refinamento por feedback explícito foi a estratégia de melhoria de dois trabalhos. Sendo eles: [Wu et al. 2024] [Iglesias et al. 2018].

No artigo [Iglesias et al. 2018] foi a AUI desenvolvida com o objetivo de monitorar Sistemas Ciber-Físicos Industriais (ICPSs), como armazéns automatizados, permite a visualização adaptativa dos dados coletados desses sistemas em tempo real.

As preferências do usuário e as relações entre eles, possibilitam a geração automática de elementos gráficos. O refinamento da interface ocorre principalmente por meio de feedback explícito do usuário, que pode configurar manualmente os elementos visuais, criar novas visualizações, responder a alertas gerados pelo sistema. Essas interações são registradas nos modelos do sistema e utilizadas para atualizar automaticamente as visualizações.

O trabalho de [Carrera-Rivera et al. 2024] destacou-se por integrar estratégias de refinamento da interface adaptativa de forma combinada. Além de aprimorar continuamente o sistema conforme a coleta de novos dados de interação dos usuários, os autores também implementaram um mecanismo de feedback explícito. Na aplicação desenvolvida, os usuários podem avaliar os serviços recomendados por meio de emoticons (triste, indiferente e feliz), os quais correspondem a uma escala numérica de 1 a 3. Essa abordagem híbrida permite ajustes mais precisos do modelo do usuário, combinando tanto a observação passiva das interações quanto a entrada direta e intencional dos usuários.

Esse tipo de estratégia ilustra bem a complexidade envolvida no desenvolvimento de sistemas de personalização, um campo que, segundo [Zanker et al. 2019], é essencialmente multidisciplinar. Ele reúne conhecimentos de áreas como Inteligência Artificial, Aprendizado de Máquina, Interação Humano-Computador e Sistemas de Informação, além de se fundamentar em conceitos de psicologia social e cognitiva aplicados à modelagem do usuário. Essa interdisciplinaridade reflete o desafio de construir interfaces adaptativas capazes de oferecer experiências personalizadas com base em múltiplos fatores, incluindo características individuais, contextuais e tecnológicas.

Essa interdisciplinaridade se concretiza na complexidade inerente à integração entre múltiplos componentes dos sistemas de personalização, incluindo dados de uso, contexto do usuário, elementos da interface e mecanismos de recomendação [Carrera-Rivera et al. 2024].

Nesse cenário, a Interação Humano-Computador (IHC) revela-se de suma importância, pois os Grandes Desafios de IHC-BR 2025-2035 - GC7: Interação com Tecnologias Emergentes [Zaina et al. 2024] propõem fomentar a integração harmoniosa entre pessoas, tecnologias e ambientes. Em um ecossistema dinâmico e interconectado, o contexto se destaca como elemento central, influenciando tanto o comportamento dos usuários quanto a adaptabilidade das interfaces.

3.2. QP2: Quais tipos de dados de uso dos usuários são mais relevantes para a implementação de AUI ?

Para responder à questão de pesquisa, foi preciso considerar tanto os tipos de dados utilizados quanto o contexto de sua aplicação. Assim, a análise das interfaces nas quais as AUIs são desenvolvidas tornou-se fundamental, conforme ilustrado na Tabela 6.

A análise dos artigos selecionados revelou uma considerável diversidade quanto aos tipos de interface utilizados, destacando-se inicialmente as interfaces tradicionais (Web, Mobile e Desktop) que apresentaram maior incidência, evidenciando sua ampla aceitação e aplicação no campo estudado. Em seguida, foram identificadas interfaces classificadas como Mistas, que integram múltiplos formatos tradicionais de forma combinada, sem se restringirem a uma única categoria. Além dessas, também foram encontradas interfaces Imersivas, tais como Realidade Virtual e Realidade Aumentada,

bem como Interfaces Alternativas, que englobam soluções inovadoras e especializadas, desviando-se dos padrões convencionais de IHC, muitas vezes voltadas para contextos específicos ou tecnologias emergentes, como Smart TVs, telas táteis de grande formato e interfaces baseadas em sinais biossensoriais, representando abordagens menos comuns, porém relevantes e promissoras no cenário tecnológico atual.

Tabela 6. Tipos de Interfaces e Respectivas Referências

Tipo de Interface	Referências
Web	[Awada et al. 2018], [Kolekar et al. 2018], [Suryani et al. 2024], [Laguna Salvadó et al. 2022], [Cherukuri 2024], [Märtin and Herdin 2024], [Wu et al. 2024], [Iglesias et al. 2018], [Yera et al. 2019], [Zhang and Sundar 2019], [Yeroshkin and Sobecki 2024], [Manoharan et al. 2024], [Finne et al. 2022], [Costa et al. 2024], [Khamaj and Ali 2024], [Sun et al. 2024]
Mobile	[Romero et al. 2020], [Ali et al. 2024], [Jo and Cho 2019], [Miraz et al. 2021], [Rei et al. 2024], [Wang et al. 2024b], [Grua et al. 2022], [Pfeuffer and Li 2018], [Zhang et al. 2024], [Melchiorre et al. 2022], [Yeo et al. 2023], [Iqbal et al. 2021], [Carrera-Rivera et al. 2023]
Desktop	[Conati et al. 2021], [Smereka et al. 2023], [Diego-Mas et al. 2019]
Mistas	[Carrera-Rivera et al. 2024], [Akiki 2018], [Silva et al. 2021], [Çağla Çığ Karaman and Sezgin 2018], [Sobecki et al. 2020]
Interfaces Imersivas	[Chew et al. 2021], [Lu et al. 2024], [Zhao and Cheng 2023], [Gomi et al. 2023]
Interfaces Alternativas	[Madduri et al. 2023], [Wang and Li 2024], [Wang et al. 2023], [Khan and Khusro 2023]

Os tipos de dados coletados dos usuários foram organizados em cinco categorias: demográficos, contextuais, comportamentais, preferências explícitas e fisiológicos. Essa classificação se baseia na recorrência das informações nos estudos e em padrões de revisões sistemáticas anteriores [Wang et al. 2024a]. A Tabela 7 correspondente apresenta os artigos analisados e os dados coletados.

O tipo de dado mais frequente é o comportamental, representando as interações diretas dos usuários com a aplicação. Essas interações podem ser observadas por meio de ações como cliques na tela [Jo and Cho 2019], movimentos do mouse [Yera et al. 2019] ou, em estudos envolvendo interfaces imersivas, como o realizado por [Lu et al. 2024], que coleta informações como a direção em que o usuário está olhando, posição das mãos e da cabeça. Dessa forma, diferentes trabalhos têm utilizado esses padrões de uso para adaptar as interfaces ao comportamento específico de cada usuário.

Tabela 7. Artigos por tipo de dado utilizado

Artigo	Context.	Demogr.	Comport.	Pref. Explicitas	Fisiol.
[Rathnayake et al. 2019]			X	X	
[Carrera-Rivera et al. 2024]	X		X	X	
[Awada et al. 2018]	X	X	X	X	X
[Kolekar et al. 2018]			X	X	
[Suryani et al. 2024]			X	X	X
[Laguna Salvadó et al. 2022]				X	
[Cherukuri 2024]			X	X	
[Märtin and Herdin 2024]	X		X	X	X
[Wu et al. 2024]				X	
[Yera et al. 2019]			X		
[Yeroshkin and Sobecki 2024]			X	X	
[Manoharan et al. 2024]			X	X	
[Finne et al. 2022]		X	X	X	
[Conati et al. 2021]			X	X	X
[Costa et al. 2024]		X	X	X	
[Romero et al. 2020]	X		X		
[Ali et al. 2024]	X		X		
[Jo and Cho 2019]	X		X		
[Miraz et al. 2021]			X	X	
[Rei et al. 2024]			X	X	
[Wang et al. 2024b]			X	X	X
[Pfeuffer and Li 2018]			X		X
[Zhang et al. 2024]			X		
[Melchiorre et al. 2022]			X	X	
[Yeo et al. 2023]			X		
[Iqbal et al. 2021]	X	X	X		
[Smereka et al. 2023]	X		X		
[Chew et al. 2021]			X		X
[Khamaj and Ali 2024]			X		
[Sun et al. 2024]			X		
[Akiki 2018]	X		X		
[Silva et al. 2021]			X		
[Çağla Çığ Karaman and Sezgin 2018]			X	X	X
[Sobecki et al. 2020]	X	X	X		
[Carrera-Rivera et al. 2023]	X		X		
[Lu et al. 2024]			X		
[Gomi et al. 2023]			X	X	
[Zhao and Cheng 2023]			X		X
[Wang et al. 2023]			X	X	
[Khan and Khusro 2023]	X	X	X	X	X
[Diego-Mas et al. 2019]			X		X
[Iglesias et al. 2018]				X	
[Zhang and Sundar 2019]		X		X	
[Grua et al. 2022]	X	X		X	
[Madduri et al. 2023]					X
[Wang and Li 2024]					X

Ao analisar as informações apresentadas na Tabela 7, é possível constatar que cerca de 90% dos autores dos artigos incluídos nesta pesquisa optaram pelo uso combinado de múltiplos tipos de dados do usuário, evidenciando uma tendência para

abordagens mais abrangentes na coleta de informações.

O artigo [Awada et al. 2018] explora uma abrangente combinação de diferentes tipos de dados dos usuários, como demográficos (por exemplo, idade e condição cognitiva), contextuais (dispositivos utilizados e ambiente), comportamentais (interações com a interface, uso de gestos ou comandos de voz), preferências explícitas (configurações escolhidas, idioma e personalização) e fisiológicos (estado emocional detectado por meio de sensores e medições de saúde). Com o objetivo de promover uma personalização da interface. Esses dados são integrados por meio de uma classificação baseada em árvores de decisão, que associa as características individuais do usuário a um conjunto de regras capazes de adaptar dinamicamente o sistema às suas necessidades específicas. Dessa forma, a interface se ajusta tanto na navegação quanto no conteúdo, oferecendo um suporte mais adequado para o público idoso, especialmente para aqueles com demência, levando em conta seu perfil único, em constante evolução ao longo do tempo.

Apesar do grande volume e da variedade de dados gerados pelas tecnologias emergentes [Zaina et al. 2024], a precisão e a compatibilidade com o contexto continuam sendo fatores cruciais para o sucesso dessas soluções, conforme destacado por [Carrera-Rivera et al. 2024]. Isso reforça a importância da qualidade dos dados, especialmente para o funcionamento eficaz das interfaces adaptativas, já que ela permite ao sistema personalizar a experiência do usuário de forma mais precisa e relevante.

No entanto, é importante considerar que uma precisão excessiva nas recomendações pode, ironicamente, restringir a possibilidade de descoberta de experiências inesperadas. Como apontado por [Zanker et al. 2019], recomendações altamente específicas tendem a reduzir a probabilidade de exposição a conteúdos fortuitos, evidenciando um desafio conhecido como serendipidade na personalização: como equilibrar acurácia com a abertura para novas e imprevisíveis experiências.

Além disso, para que as interfaces se adaptem de maneira eficaz sem sofrer com a escassez de dados, é necessário encontrar um equilíbrio entre especificidade e generalização. Conforme observado por [Carrera-Rivera et al. 2024], adotar um certo nível de generalização nos dados contextuais ajuda a prevenir a esparsidade que poderia surgir caso as informações fossem excessivamente específicas.

4. Considerações finais

Este estudo teve como objetivo identificar quais são os dados mais relevantes para coleta, os métodos mais utilizados para análise e as abordagens predominantes na adaptação de interfaces, visando a personalização e otimização da experiência do usuário em sistemas de interfaces adaptativas. Para isso, foi realizada uma revisão sistemática da literatura, que permitiu mapear o estado da arte sobre o tema e sintetizar tendências e práticas emergentes.

Os resultados obtidos evidenciam que a maioria dos estudos selecionados emprega técnicas de inteligência artificial e suas técnicas, como mecanismos centrais para a implementação de adaptações automatizadas. Dentre os tipos de dados utilizados, os dados comportamentais, oriundos das interações diretas dos usuários com a interface, sendo cliques, movimentos do mouse e padrões de navegação, os mais frequentemente

aplicados. No entanto, também se destacaram os dados contextuais, preferências explícitas e, em menor escala, os dados demográficos e fisiológicos, muitas vezes combinados com outros tipos de informação auxiliando o enriquecimento do modelo adaptativo e aumentando a precisão das personalizações.

As adaptações mais comuns ocorrem de forma automática e em tempo real, com refinamento incremental ao longo do tempo, baseado na evolução do perfil do usuário e nas mudanças de contexto. Essa abordagem permite que a interface se ajuste continuamente às necessidades do usuário, oferecendo uma experiência personalizada. Ainda assim, alguns estudos optaram por adaptações semi-automáticas ou até manuais, buscando preservar o controle e a autonomia do usuário frente a alterações automáticas.

Apesar dos avanços observados, a pesquisa revelou desafios associados à qualidade dos dados utilizados e à complexidade dos modelos adaptativos. A eficácia das interfaces depende fortemente da precisão e representatividade dos dados coletados, especialmente quando se busca generalizar padrões de uso sem comprometer a individualidade do usuário. Além disso, a integração de múltiplas fontes de dados e a aplicação de algoritmos sofisticados exigem soluções técnicas capazes de lidar com a variabilidade dos contextos de uso e com a dinamicidade do comportamento humano.

Esses desafios evidenciam a necessidade de uma abordagem colaborativa, na qual diferentes áreas contribuam com suas perspectivas e metodologias. Este estudo, por sua vez, destaca a importância da interdisciplinaridade no desenvolvimento de interfaces adaptativas, evidenciando a integração entre áreas como Inteligência Artificial, IHC, Ciência de Dados. Essa abordagem convergente permite não apenas a criação de sistemas mais inteligentes, mas também a construção de experiências digitais mais inclusivas e centradas no usuário. Em um cenário cada vez mais digitalizado e conectado, as interfaces adaptativas destacam-se como tecnologias emergentes capazes de transformar a maneira como os usuários se relacionam com os sistemas, respondendo dinamicamente às suas necessidades, contextos e perfis individuais. No entanto, o sucesso dessas soluções depende diretamente da qualidade dos dados coletados e da capacidade de lidar com a complexidade dos modelos adaptativos, desafios que exigem tanto avanços técnicos quanto reflexões éticas e metodológicas contínuas.

Nesse contexto, é possível observar que os estudos abordados nesta pesquisa integram os Grandes Desafios de Pesquisa em Interação Humano-Computador [Pereira et al. 2024], delineados pela CEIHC para o período de 2025 a 2035. A investigação conduzida se articula de forma transversal entre diversos desafios, com ênfase particular no GC7: Interação com Tecnologias Emergentes – Um Ecossistema que Integra Humanos, Tecnologias e Contextos [Zaina et al. 2024].

Apesar deste estudo trazer importantes contribuições, existem algumas limitações inerentes à pesquisa. A análise foi restrita ao período entre 2018 e 2024, o que pode ter resultado na exclusão de estudos relevantes publicados anteriormente. Além disso, embora a metodologia PRISMA e os critérios de avaliação tenham garantido rigor e qualidade na seleção dos estudos, a natureza predominantemente qualitativa da análise pode ter deixado de capturar nuances quantitativas mais amplas. Também se reconhece que, por se tratar de uma revisão sistemática centrada em literatura científica indexada, aplicações práticas e soluções emergentes descritas em fontes cinzentas (como

relatórios técnicos ou documentação de sistemas) não foram contempladas, o que pode limitar a abrangência dos achados frente ao estado da prática. Tais limitações apontam caminhos importantes para aprofundamentos futuros, incluindo revisões integrativas ou mapeamentos ampliados com outras abordagens metodológicas.

Outra limitação relevante refere-se à escassez de discussões aprofundadas sobre aspectos éticos e de privacidade. Embora alguns estudos mencionem brevemente preocupações com segurança e consentimento, poucos discutem de forma detalhada os desafios envolvendo o uso responsável de dados sensíveis, especialmente no contexto de coleta e processamento automatizado. Questões como transparência nas decisões algorítmicas, controle do usuário sobre seus dados e possíveis vieses nas adaptações personalizadas são subexploradas, evidenciando uma lacuna crítica para a aplicação prática e ética dessas tecnologias em contextos reais e regulamentados.

Como trabalho futuro, pretende-se aplicar os conhecimentos obtidos nesta pesquisa na implementação de uma Interface Adaptativa em um aplicativo dedicado à gestão de cultivos hortícolas. A interface será desenvolvida com base em técnicas de inteligência artificial, inicialmente apoiadas em regras manuais pré-definidas, evoluindo progressivamente para algoritmos de aprendizado de máquina conforme o volume de dados coletados aumentar. Os dados utilizados serão de natureza comportamental, como padrões de uso, interações com os conteúdos e tempo gasto em cada funcionalidade, além de informações demográficas, tais como cargo, localização geográfica, nível de experiência e perfil técnico do usuário. Os dados coletados servirão para classificar os usuários em diferentes grupos ou níveis de conhecimento, possibilitando a filtragem e personalização dinâmica do conteúdo exibido, de forma a atender às necessidades específicas de cada perfil.

Essa abordagem fundamenta-se nas diretrizes identificadas a partir da revisão de estudos sobre interfaces adaptativas, cujas contribuições foram fundamentais para a idealização desta solução. Assim, as reflexões obtidas ao longo da produção deste artigo reforçam o papel da inteligência artificial e a utilização estratégica dos dados do usuário no desenvolvimento de experiências personalizadas. Além disso, os princípios discutidos mostram que essa abordagem pode ser aplicada em outros contextos, evidenciando seu amplo potencial em diferentes domínios.

5. Considerações Éticas

Todos os protocolos éticos foram seguidos durante a elaboração deste trabalho. Por se tratar de uma RSL, não houve realização de pesquisa com seres humanos nem coleta de dados pessoais. Dessa forma, não foi necessária a submissão ao Comitê de Ética em Pesquisa. Este estudo respeita integralmente os princípios éticos e legais aplicáveis à pesquisa acadêmica.

6. Agradecimentos

Este trabalho contou com o apoio de inteligência artificial generativa, especialmente o assistente de IA ChatGPT, utilizado como ferramenta auxiliar na compreensão de conteúdos complexos dos artigos analisados. O ChatGPT foi empregado para parafrasear trechos técnicos, esclarecer termos e conceitos, e apoiar na organização e estruturação textual. Não foi utilizado para classificação ou análise sistemática dos artigos.

Referências

- Akiki, P. A. (2018). Chain: Developing model-driven contextual help for adaptive user interfaces. In *Proceedings of Journal of Systems and Software*, pages 165–190. Elsevier.
- Ali, M., Khan, S., and Mashkoo, A. (2024). A conceptual framework for context-driven self-adaptive intelligent user interface based on android. In *Proceedings of Cognition, Technology Work*, pages 83–106. Springer.
- Awada, I. A., Mocanu, I., Nastac, D.-I., Benta, D., and Radu, S. (2018). Adaptive user interface for healthcare application for people with dementia. In *2018 17th RoEduNet Conference: Networking in Education and Research (RoEduNet)*, pages 1–5. IEEE.
- Carrera-Rivera, A., Larrinaga, F., and Las, G. (2024). Adaptui: A framework for the development of adaptive user interfaces in smart product-service systems. In *Proceedings of User Modeling and User-Adapted Interaction*, pages 1929–1980. Springer.
- Carrera-Rivera, A., Reguera-Bakhache, D., and Larrinaga, F. (2023). Structured dataset of human-machine interactions enabling adaptive user interfaces. In *Proceedings of Scientific Data*, page 831. Springer Nature.
- Cherukuri, B. R. (2024). Development of design patterns with adaptive user interface for cloud native microservice architecture using deep learning with iot. In *2024 IEEE International Conference on Computing, Power and Communication Technologies (IC2PCT)*, pages 1866–1871. IEEE.
- Chew, J. Y., Kawamoto, M., Okuma, T., Yoshida, E., and Kato, N. (2021). Multi-modal approach to evaluate adaptive visual stimuli of remote operation system using gaze behavior. In *Proceedings of International Journal of Industrial Ergonomics*, page 103223. Elsevier.
- Conati, C., Barral, O., Putnam, V., and Rieger, L. (2021). Toward personalized xai: A case study in intelligent tutoring systems. In *Proceedings of Artificial Intelligence*, page 103503. Elsevier.
- Costa, A., Silva, F., and Moreira, J. J. (2024). Towards an ai-driven user interface design for web applications. In *Proceedings of Procedia Computer Science*, pages 179–186. Elsevier.
- Diego-Mas, J. A., Garzon-Leal, D., Poveda-Bautista, R., and Alcaide-Marzal, J. (2019). User-interfaces layout optimization using eye-tracking, mouse movements and genetic algorithms. In *Proceedings of Applied Ergonomics*, pages 197–209. Elsevier.
- ElSayed, N., Veas, E., and Schmalstieg, D. (2024). Agents of mask: Mobile analytics from situated knowledge. In *Interactions*, pages 48–55, New York, NY, USA. Association for Computing Machinery.
- Finne, R., Larsson, L., Mylonopoulou, V., Andreasson, S., Hjelm, T., Rost, M., Weilenmann, A., and Torgersson, O. (2022). Reversed multi-layer design as an approach to designing for digital seniors. In *Nordic Human-Computer Interaction Conference*, page 5, New York, NY, USA. Association for Computing Machinery.

- Gomi, R., Takashima, K., Onishi, Y., Fujita, K., and Kitamura, Y. (2023). Ubisurface: A robotic touch surface for supporting mid-air planar interactions in room-scale vr. In *Proceedings of ACM Human-Computer Interaction*, page 443, New York, NY, USA. Association for Computing Machinery.
- Grua, E. M., De Sanctis, M., Malavolta, I., Hoogendoorn, M., and Lago, P. (2022). An evaluation of the effectiveness of personalization and self-adaptation for e-health apps. In *Proceedings of Information and Software Technology*, page 106841. Elsevier.
- Iglesias, A., Yue, T., Arellano, C., Ali, S., and Sagardui, G. (2018). Model-based personalized visualization system for monitoring evolving industrial cyber-physical system. In *2018 25th Asia-Pacific Software Engineering Conference (APSEC)*, pages 532–541. IEEE.
- Iqbal, M. W., Ch, N. A., Shahzad, S. K., Naqvi, M. R., Khan, B. A., and Ali, Z. (2021). User context ontology for adaptive mobile-phone interfaces. *IEEE Access*, 9:96751–96762.
- Jo, S.-M. and Cho, S.-B. (2019). A personalized context-aware soft keyboard adapted by random forest trained with additional data of same cluster. In *Proceedings of Neurocomputing*, pages 17–27. Elsevier.
- Khamaj, A. and Ali, A. M. (2024). Adapting user experience with reinforcement learning: Personalizing interfaces based on user behavior analysis in real-time. In *Proceedings of Alexandria Engineering Journal*, pages 164–173. Elsevier.
- Khan, M. and Khusro, S. (2023). Towards the design of personalized adaptive user interfaces for smart tv viewers. In *Proceedings of Journal of King Saud University - Computer and Information Sciences*, page 101777. Elsevier.
- Kitchenham, B., Pearl Brereton, O., Budgen, D., Turner, M., Bailey, J., and Linkman, S. (2009). Systematic literature reviews in software engineering – a systematic literature review. *Information and Software Technology*, 51(1):7–15.
- Kolekar, S. V., Pai, R. M., and Pai M.M., M. (2018). Adaptive user interface for moodle based e-learning system using learning styles. In *Proceedings of Procedia Computer Science*, pages 606–615. Elsevier.
- Laguna Salvadó, L., Villeneuve, E., Masson, D., Abi Akle, A., and Bur, N. (2022). Decision support system for technology selection based on multi-criteria ranking: Application to nzeb refurbishment. In *Proceedings of Building and Environment*, page 108786. Elsevier.
- Lu, F., Chen, M., Hsu, H., Deshpande, P., Wang, C. Y., and MacIntyre, B. (2024). Adaptive content placement in mixed reality through empirical user behavioral patterns. In *2024 IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct)*, pages 199–204. IEEE.
- Madduri, M. M., Burden, S. A., and Orsborn, A. L. (2023). Biosignal-based co-adaptive user-machine interfaces for motor control. In *Proceedings of Current Opinion in Biomedical Engineering*, page 100462. Elsevier.

- Manoharan, S. K., Megalingam, R. K., and Lazar, A. M. A. (2024). Reconfigurable ui/ux design for robotic applications based on user experience. In *2024 4th Asian Conference on Innovation in Technology (ASIANCON)*, pages 1–6. IEEE.
- Melchiorre, A. B., Penz, D., Ganhör, C., Lesota, O., Fragoso, V., Friztl, F., Parada-Cabaleiro, E., Schubert, F., and Schedl, M. (2022). Emomtb: Emotion-aware music tower blocks. In *Proceedings of the 2022 International Conference on Multimedia Retrieval*, pages 206–210, New York, NY, USA. Association for Computing Machinery.
- Miraz, M. H., Ali, M., Excell, P. S., and Khan, S. (2021). Ai-based culture independent pervasive m-learning prototype using ui plasticity design. In *Proceedings of Computers, Materials and Continua*, pages 1021–1039. Tech Science Press.
- Moher, D., Liberati, A., Tetzlaff, J., and Altman, D. (2010). Preferred reporting items for systematic reviews and meta-analyses: The prisma statement. In *Proceedings of the International Journal of Surgery*, pages 336–341. Elsevier.
- Märtn, C. and Herdin, C. (2024). Enabling real-time adaptations for individualized customer experience in user-centered e-business applications. In *Proceedings of Procedia Computer Science*, pages 1425–1432. Elsevier.
- Okopnyi, P., Nordberg, O. E., and Guribye, F. (2024). Against generative ui. In *Proceedings of the Halfway to the Future Symposium*, page 12, New York, NY, USA. Association for Computing Machinery.
- Pereira, R., Darin, T., and Silveira, M. S. (2024). Grandihc-br: Grand research challenges in human-computer interaction in brazil for 2025-2035. In *Proceedings of the XXIII Brazilian Symposium on Human Factors in Computing Systems, IHC '24*, New York, NY, USA. Association for Computing Machinery.
- Pfeuffer, K. and Li, Y. (2018). Analysis and modeling of grid performance on touchscreen mobile devices. In *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems*, pages 1–12, New York, NY, USA. Association for Computing Machinery.
- Rathnayake, N., Meedeniya, D., Perera, I., and Welivita, A. (2019). A framework for adaptive user interface generation based on user behavioural patterns. In *2019 Moratuwa Engineering Research Conference (MERCon)*, pages 698–703. IEEE.
- Rei, D., Clavel, C., Martin, J.-C., and Ravenet, B. (2024). Adapting goals and motivational messages on smartphones for motivation to walk. In *Proceedings of Smart Health*, page 100482. Elsevier.
- Romero, O. J., Haig, A., Kirabo, L., Yang, Q., Zimmerman, J., Tomasic, A., and Steinfeld, A. (2020). A long-term evaluation of adaptive interface design for mobile transit information. In *22nd International Conference on Human-Computer Interaction with Mobile Devices and Services*, page 39, New York, NY, USA. Association for Computing Machinery.
- Silva, K. G. G. H., Abeyasekare, W. A. P. S., Dasanayake, D. M. H. E., Nandisena, T. B., Kasthurirathna, D., and Kugathanan, A. (2021). Dynamic user interface personalization based on deep reinforcement learning. In *2021 3rd International Conference on Advancements in Computing (ICAC)*, pages 25–30. IEEE.

- Smreka, M., Kołaczek, G., Sobecki, J., and Wasilewski, A. (2023). Adaptive user interface for workflow-erp system. In *Proceedings of Procedia Computer Science*, pages 2381–2391. Elsevier.
- Sobecki, J., Wasilewski, A., and Kołaczek, G. (2020). Self-adaptation of workflow business software to the user's requirements and behavior. In *Proceedings of Procedia Computer Science*, pages 3506–3513. Elsevier.
- Sun, Q., Xue, Y., and Song, Z. (2024). Adaptive user interface generation through reinforcement learning: A data-driven approach to personalization and optimization. In *2024 6th International Conference on Frontier Technologies of Information and Computer (ICFTIC)*, pages 1386–1391. IEEE.
- Suryani, M., Sensuse, D., and Santoso, H. (2024). An initial user model design for adaptive interface development in learning management system based on cognitive load. In *Proceedings of Cognition, Technology Work*, pages 653–672. Springer.
- Wang, J. and Li, J. (2024). Human body features recognition based adaptive user interface for extra-large touch screens. In *Proceedings of Displays*, page 102838. Elsevier.
- Wang, W., Gai, W., Zang, C., Bao, X., and Yang, C. (2023). Personalized recommendation of user interfaces based on foot interaction. In *2023 IEEE Smart World Congress (SWC)*, pages 1–8. IEEE.
- Wang, W., Khalajzadeh, H., and Grundy, J. (2024a). Adaptive user interfaces in systems targeting chronic disease: A systematic literature review. In *Proceedings of User Modeling and User-Adapted Interaction*, pages 853–920. Springer.
- Wang, W., Khalajzadeh, H., Grundy, J., Madugalla, A., and Obie, H. O. (2024b). Adaptive user interfaces for software supporting chronic disease. In *Proceedings of the 46th International Conference on Software Engineering: Software Engineering in Society*, pages 118–129, New York, NY, USA. Association for Computing Machinery.
- Wu, J., Todi, K., Chan, J., Myers, B. A., and Lafreniere, B. (2024). Framekit: A tool for authoring adaptive uis using keyframes. In *Proceedings of the 29th International Conference on Intelligent User Interfaces*, pages 660–674, New York, NY, USA. Association for Computing Machinery.
- Yeo, H.-S., Wu, E., Kim, D., Lee, J., il Kim, H., Oh, S. Y., Takagi, L., Woo, W., Koike, H., and Quigley, A. J. (2023). Omnisense: Exploring novel input sensing and interaction techniques on mobile device with an omni-directional camera. In *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems*, page 530, New York, NY, USA. Association for Computing Machinery.
- Yera, A., Muguerza, J., Arbelaitz, O., Perona, I., Keers, R. N., Ashcroft, D. M., Williams, R., Peek, N., Jay, C., and Vigo, M. (2019). Modelling the interactive behaviour of users with a medication safety dashboard in a primary care setting. In *Proceedings of International Journal of Medical Informatics*, pages 395–403. Elsevier.
- Yeroshkin, O. and Sobecki, J. (2024). Recommendations user interface in web-based e-commerce systems. In *Proceedings of Procedia Computer Science*, pages 2874–2881. Elsevier.

- Zaina, L., Prates, R. O., Silva, S. E. D., Choma, J., Valentim, N. M. C., Frigo, L. B., and de Lima Bicho, A. (2024). Grandihc-br 2025-2035 - gc7: Interaction with emerging technologies: An ecosystem integrating humans, technologies, and contexts. In *Proceedings of the XXIII Brazilian Symposium on Human Factors in Computing Systems (IHC '24)*, pages 1–21. ACM.
- Zanker, M., Rook, L., and Jannach, D. (2019). Measuring the impact of online personalisation: Past, present and future. In *Proceedings of International Journal of Human-Computer Studies*, pages 160–168. Elsevier.
- Zhang, B. and Sundar, S. S. (2019). Proactive vs. reactive personalization: Can customization of privacy enhance user experience? In *Proceedings of International Journal of Human-Computer Studies*, pages 86–99. Elsevier.
- Zhang, R., Wang, S., Xie, T., Duan, S., and Chen, M. (2024). Dynamic user interface generation for enhanced human-computer interaction using variational autoencoders. In *2024 4th International Conference on Communication Technology and Information Technology (ICCTIT)*, pages 260–265. IEEE.
- Zhao, S. and Cheng, S. (2023). Adaptive navigation assistance based on eye movement features in virtual reality. In *Proceedings of Virtual Reality and Intelligent Hardware*, pages 232–248. Elsevier.
- Çağla Çığ Karaman and Sezgin, T. M. (2018). Gaze-based predictive user interfaces: Visualizing user intentions in the presence of uncertainty. In *Proceedings of International Journal of Human-Computer Studies*, pages 78–91. Elsevier.