

Interfaces Adaptativas: Explorando Algoritmos de Aprendizado de Máquina para a Personalização de Experiências do Usuário

Felipe William Galdino da Silva¹, Reyner Carlos Silva Alegria²,
Lais Samily Xavier da Silva³, Andrey Antonio de Oliveira Rodrigues⁴

^{1,2,3,4}Engenharia de Software – Instituto de Ciências Exatas e Tecnológica
Itacoatiara – AM – Brasil

felipe.silva@ufam.edu.br¹, reyner.alegria@ufam.edu.br²,
samily.xavier@ufam.edu.br³, andrey.rodrigues@ufam.edu.br⁴

Abstract. *The personalization of user interfaces through machine learning algorithms is an increasingly relevant field in Human-Computer Interaction (HCI), aiming to develop systems that dynamically adapt to individual user needs and preferences. This study reports a Systematic Literature Mapping (SLM) that critically analyzed scientific studies to investigate current approaches. The analysis focused on the predominant machine learning algorithms, the methods used to collect user data, and the adaptation strategies applied to personalize the user experience. The findings provide a consolidated overview that contributes to the theoretical advancement of the field by identifying mature approaches, existing gaps, and research opportunities. Finally, the study highlights trends that can guide the development of future interfaces that are more effective, inclusive, and user-centered.*

Resumo. *A personalização de interfaces de usuário via algoritmos de aprendizado de máquina é um campo de crescente interesse na Interação Humano-Computador (IHC), buscando criar sistemas que se adaptem dinamicamente às necessidades e preferências individuais dos usuários. Este trabalho reporta um Mapeamento Sistemático da Literatura (MSL) que analisou estudos científicos para investigar criticamente as abordagens existentes. A análise focou nos algoritmos de aprendizado de máquina predominantes, nos métodos utilizados para coletar dados dos usuários e nas estratégias de adaptação aplicadas para personalizar a experiência de uso. Os achados oferecem uma visão consolidada que contribui para o avanço teórico da área, identificando as abordagens mais maduras, lacunas existentes e oportunidades de pesquisa. Por fim, o estudo aponta tendências que podem guiar o desenvolvimento de futuras interfaces mais eficazes, inclusivas e centradas no usuário.*

1. Introdução

A Interação Humano-Computador (IHC) é cada vez mais central na sociedade digital, e a integração de algoritmos de aprendizado de máquina (aprendizado de máquina) oferece um potencial transformador para a criação de interfaces adaptativas [Dudley and Kristensson 2018, Xu et al. 2023]. Em contraste com as interfaces

estáticas tradicionais, as adaptativas podem se ajustar dinamicamente ao comportamento e às necessidades individuais dos usuários, prometendo uma experiência mais eficaz, personalizada e inclusiva [Canito et al. 2020, Todi et al. 2021]. No entanto, a realização desse potencial enfrenta desafios significativos, incluindo a complexidade algorítmica, a diversidade de dados para personalização e as implicações éticas na coleta de dados do usuário [Bécue et al. 2021, Zhu et al. 2020].

Apesar do interesse crescente, a falta de uma visão consolidada sobre as abordagens existentes pode dificultar o avanço sistemático da área. Para endereçar essa lacuna, o objetivo deste trabalho é investigar e compreender, por meio de um Mapeamento Sistemático da Literatura (MSL), como algoritmos de aprendizado de máquina são aplicados para adaptar interfaces de usuário às suas preferências e necessidades. A investigação abrange a identificação dos principais algoritmos utilizados, a análise dos métodos de coleta de dados empregados para capturar as interações do usuário e a síntese das estratégias de personalização propostas na literatura.

As principais contribuições deste trabalho são, portanto: (1) um panorama consolidado das pesquisas publicadas sobre o tema; (2) a identificação dos algoritmos de aprendizado de máquina e estratégias de personalização mais proeminentes; e (3) o apontamento de tendências, desafios e lacunas que podem nortear futuras pesquisas.

O presente artigo está organizado da seguinte forma: a Seção 2 aborda o referencial teórico, a Seção 3 detalha a metodologia do MSL, a Seção 4 apresenta os resultados obtidos, e por fim, a Seção 5 conclui o trabalho.

2. Referencial Teórico

2.1. Interfaces Adaptativas

Interfaces adaptativas são sistemas de interface de usuário que têm a capacidade de se ajustar dinamicamente com base nas preferências, necessidades e características individuais dos usuários [Todi et al. 2021]. Essas interfaces visam fornecer experiências personalizadas, otimizando a interação entre o usuário e o sistema digital. Uma das características essenciais das interfaces adaptativas é sua capacidade de aprender com o comportamento passado do usuário e de se adaptar de forma proativa para melhor atendê-lo. Essa adaptação pode ocorrer em diferentes níveis, desde a personalização de conteúdo até a reorganização da própria estrutura da interface [Todi et al. 2021, Miraz et al. 2021].

Essas interfaces são fundamentadas em uma abordagem centrada no usuário, que reconhece a diversidade de habilidades, preferências e contextos dos usuários [Shneiderman and Plaisant 2010]. Tal abordagem busca criar sistemas tecnológicos que se adaptem dinamicamente às necessidades individuais, proporcionando uma experiência mais personalizada e eficaz. Para isso, as interfaces adaptativas utilizam técnicas como a modelagem de preferências do usuário, a análise de interações passadas e a adaptação em tempo real, permitindo uma customização contínua da interface com base no comportamento e nas características do usuário [Browne 2016, Hussain et al. 2018]. Essa flexibilidade torna possível atender às demandas de uma ampla variedade de usuários, independentemente de suas habilidades, experiências ou preferências específicas.

As interfaces adaptativas desempenham um papel crucial na melhoria da usabilidade e na personalização da interação humano-computador em uma ampla variedade de contextos, desde sistemas de recomendação em plataformas de *streaming* de vídeo até sistemas de navegação em aplicativos móveis [Miraz et al. 2021]. Ao adaptar-se às preferências e necessidades individuais dos usuários, essas interfaces têm o potencial de aumentar a eficiência, a satisfação do usuário e a acessibilidade, promovendo assim uma experiência digital mais inclusiva e agradável [Hussain et al. 2018]. Portanto, entender os conceitos e princípios subjacentes às interfaces adaptativas é fundamental para o desenvolvimento de sistemas tecnológicos mais eficazes e centrados no usuário.

2.2. Aprendizado de Máquina aplicado à Interação Humano-Computador

Aprendizado de máquina é um subcampo da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos computacionais que podem aprender e fazer previsões ou decisões a partir de dados [Zhou 2021]. Esses algoritmos são projetados para identificar padrões nos dados e usar esses padrões para fazer inferências ou tomar ações sem intervenção humana direta [El Misilmani and Naous 2019]. Existem várias abordagens de aprendizado de máquina, incluindo aprendizado supervisionado, onde o algoritmo é treinado com exemplos rotulados; aprendizado não supervisionado, onde o algoritmo extrai padrões dos dados não rotulados; e aprendizado por reforço, onde o algoritmo aprende a tomar decisões através da interação com um ambiente [Zhou 2021].

A Interação Humano-Computador (IHC) é o campo multidisciplinar que estuda a interação entre humanos e sistemas computacionais [Barbosa and Silva 2010]. Isso inclui o design, avaliação e implementação de interfaces de usuário, bem como o estudo do impacto social e cognitivo da tecnologia digital. Os pesquisadores em IHC buscam melhorar a usabilidade, acessibilidade e experiência do usuário em uma variedade de contextos, desde aplicativos móveis e sites até sistemas de realidade virtual e dispositivos inteligentes [Baranauskas et al. 2012].

A integração entre aprendizado de máquina e interação humano-computador oferece oportunidades únicas para criar sistemas tecnológicos mais adaptativos e inteligentes. Ao aplicar técnicas de aprendizado de máquina à IHC, pode-se desenvolver interfaces de usuário que se adaptam dinamicamente com base no comportamento e nas preferências do usuário [Wang 2022]. Isso permite uma personalização mais eficaz e uma experiência do usuário mais satisfatória, além de abrir novas possibilidades para a criação de sistemas inteligentes e autônomos [Santos et al. 2021].

A mesclagem entre interface adaptativa e aprendizado de máquina representa uma evolução significativa na forma como usuários interagem com a tecnologia digital [Santos et al. 2021, Miraz et al. 2021, Todi et al. 2021]. Essa integração não apenas amplia as capacidades das interfaces de usuário, mas também promove uma interação mais natural, intuitiva e eficiente entre humanos e sistemas computacionais. Ao combinar os princípios da adaptação dinâmica com os algoritmos de aprendizado de máquina, torna-se possível criar sistemas tecnológicos que se ajustam continuamente às necessidades e preferências individuais dos usuários, proporcionando uma experiência digital mais personalizada e satisfatória.

3. Mapeamento Sistemático da Literatura

Para investigar algoritmos de aprendizado de máquina em interfaces adaptativas e personalizadas, é crucial compreender as abordagens existentes, analisando suas propostas, funcionamentos e limitações. Isso oferece uma base sólida para novas contribuições, justificando a realização de um Mapeamento Sistemático da Literatura (MSL).

O MSL é uma metodologia para identificar, categorizar e estruturar estudos científicos sobre um tema específico, facilitando sua análise [Kitchenham and Charters 2007]. Exige rigor metodológico e um protocolo bem definido, aumentando a confiabilidade dos resultados e minimizando vieses [Kitchenham and Charters 2007, Petersen et al. 2008].

A condução do MSL seguiu as diretrizes de [Kitchenham and Charters 2007], compreendendo três etapas: planejamento, execução e relato dos resultados. O planejamento resultou em um protocolo de revisão que detalhou: os objetivos do mapeamento, as questões de pesquisa (QPs), a estratégia de busca, os critérios de seleção dos estudos e o formulário para extração de dados.

3.1. Protocolo do Mapeamento Sistemático

O protocolo do MSL é essencial para a qualidade e confiabilidade do estudo, reduzindo o viés do pesquisador ao especificar métodos e critérios para todas as etapas, da definição das QPs à extração de dados [Kitchenham and Charters 2007]. Seus elementos são descritos a seguir.

3.1.1. Objetivo

O objetivo deste MSL, estruturado pelo paradigma GQM (*Goal-Question-Metric*) [Basili et al. 2002], é detalhado na Tabela 1.

Table 1. Objetivo do MSL segundo o paradigma GQM.

Analizar as	publicações científicas
com o propósito de	identificar diferentes tipos de algoritmos de aprendizado de máquina
com relação a	adaptação e personalização de interfaces do usuário
do ponto de vista dos	pesquisadores
no contexto de	de interação humano-computador e Machine Learning.

3.1.2. Questões de Pesquisa

As Questões de Pesquisa (QPs), elemento central do MSL e derivadas do objetivo estabelecido, buscam responder as seguintes QPs:

- **QP1:** Quais algoritmos de aprendizado de máquina são utilizados para as interfaces adaptativas de usuários?

- **QP2:** Como os algoritmos de aprendizado de máquina podem ser aplicados para personalizar interfaces de usuário em diferentes contextos de uso?
- **QP3:** Como os diferentes métodos de coleta de dados influenciam a eficácia da personalização de interfaces adaptativas considerando preferências e necessidades do usuário?
- **QP4:** Quais dispositivos são mais adequados para a aplicação de interfaces adaptativas baseadas em aprendizado de máquina?

3.1.3. Estratégia de Busca dos Artigos

Uma estratégia de busca bem definida é fundamental para delimitar o escopo da pesquisa e otimizar a identificação de publicações relevantes. Para este MSL, consideraram-se os seguintes elementos:

- **Fontes de busca:** Utilizaram-se as bases de dados *ACM*¹, *Engineering Village*², *IEEE Xplore*³, *Scopus*⁴ e *Wiley Library*⁵, por sua relevância em Ciência da Computação.
- **Tipo de documento:** Consideraram-se apenas artigos de conferências e periódicos revisados por pares.
- **Idioma:** Selecionaram-se artigos em inglês, idioma predominante na área.
- **Período de Publicação:** Foram incluídas apenas as publicações datadas entre 2015 e 2024. Essa escolha tem o objetivo de garantir que o resultado sejam publicações atuais e não desatualizadas.

A estratégia de busca também incluiu a formulação da *string* de busca, as quais foram executadas nas bases de dados selecionadas. A formulação dos termos da *string* foram estruturadas com base nos parâmetros do modelo *PICOC* (*Population, Intervention, Comparison, Output e Context*), propostas por [Petticrew and Roberts 2008]. Este modelo é utilizado amplamente em estudos de revisões sistemáticas, a fim de garantir que os principais elementos de uma pesquisa científica sejam incluídos. No entanto, para atender os objetivos deste MSL, os parâmetros de comparação (*Comparison*) e contexto (*Context*) não foram utilizados neste MSL, uma vez que não há comparação para determinar o contexto. Dessa forma, os termos utilizados para a formulação da *string* de busca são apresentados na Tabela 2.

¹<https://www.acm.org>

²<https://www.engineeringvillage.com>

³<https://ieeexplore.ieee.org/>

⁴<https://www.scopus.com>

⁵<https://onlinelibrary.wiley.com/>

Table 2. String de busca utilizada neste MSL.

Critérios PICOC	Strings de Busca
População	“Human-computer interaction” OR “HCI” OR “Machine Learning” OR “ML” OR “Artificial Intelligence” OR “AI” AND
Intervenção	“Machine learning algorithms” OR “ML algorithms” OR “Artificial Intelligence algorithms” OR “AI algorithms” AND
Resultados	“Adaptive interfaces” OR “Personalized interfaces” OR “Adaptive user interfaces” OR “Personalized user interfaces”

3.1.4. Critérios para seleção dos artigos

Critérios de inclusão (CI) e exclusão (CE) (Tabela 3) foram definidos para selecionar estudos relevantes aos objetivos, sendo aplicados consistentemente nas três fases de filtragem.

Table 3. Critérios de seleção dos artigos

Critérios	Critérios de inclusão
CI-1	O artigo deve abordar métodos de coleta de dados para capturar preferências e necessidades dos usuários em interfaces adaptativas.
CI-2	O artigo deve abordar o uso de Inteligência Artificial aplicado na Experiência do Usuário (UX).
CI-3	O artigo deve discutir algoritmos de aprendizado de máquina aplicados à personalização e adaptação de interfaces de usuário.
CI-4	O artigo deve investigar dispositivos adequados para a implementação de interfaces adaptativas com aprendizado de máquina.
Critérios	Critérios de exclusão
CE-1	A publicação não é um artigo científico (por exemplo, é um capítulo de livro), o que pode indicar falta de revisão por pares.
CE-2	A versão completa do artigo não está disponível para download ou nas fontes de busca.
CE-3	O artigo está duplicado, ou seja, foi retornado em outro mecanismo de busca.
CE-4	O artigo não atende a nenhum dos critérios de inclusão estabelecidos.
CE-5	O artigo não está em inglês, o que pode limitar a compreensão e análise.
CE-6	A publicação é de data anterior a 2015.

3.1.5. Formulário de Extração de Dados

Após a seleção final dos estudos, os dados relevantes de cada publicação foram extraídos utilizando um formulário pré-definido. Esses dados foram classificados em:

- **Dados da publicação** (Tabela 4): Para caracterizar os estudos (e.g., ano, fonte, tipo).

- **Dados dos algoritmos de aprendizado de máquina** (Tabela 5): Para identificar técnicas aplicadas em interfaces adaptativas (e.g., algoritmo, abordagem de adaptação, avaliação).
- **Dados da coleta e adaptação** (Tabela 6): Para compreender métodos de coleta de dados do usuário e adaptação da interface (e.g., tipo de dado coletado, método de coleta, dispositivos).

Table 4. Dados específicos da publicação

Ano de Publicação	Ano em que o artigo foi publicado.
Fonte	Veículo em que foi publicado.
Título	Título da publicação.
Autores	Lista de autores responsáveis pela pesquisa.
Tipo de Publicação	Artigo, Conference paper, ou Review.

Table 5. Dados específicos dos algoritmos de aprendizado de máquina

Algoritmo	Identificação dos algoritmos de aprendizado de máquina descritos.
Abordagem de Adaptação	Estratégia utilizada para adaptar a interface com base nos dados coletados.
Avaliação do Algoritmo	Critérios utilizados para avaliar a eficácia do algoritmo no estudo.

Table 6. Dados específicos da coleta

Tipo de Dados Coletados	Tipo de dados coletados sobre o usuário.
Método de Coleta	Método e contexto usado para capturar as preferências do usuário.
Dispositivos Utilizados	Dispositivos em que o sistema foi implementado.

3.2. Execução do Mapeamento Sistemático

Para a execução do MSL, as *strings* de busca definidas na Tabela 2 foram aplicadas nas bases de dados selecionadas. O resultado dessa busca foi armazenado e organizado na ferramenta *Parcifal*⁶, que auxiliou no processo de seleção colaborativa pelos pesquisadores envolvidos. Tal ferramenta possibilitou um maior controle e rastreabilidade nas etapas deste mapeamento, garantindo que os critérios de inclusão e exclusão (Tabela 3) fossem aplicados de modo sistemático e constante nas etapas deste MSL. Essas etapas no processo de execução foram definidas em três etapas de seleção:

⁶<https://parsif.al/>

- **Processo de seleção preliminar (1º Filtro):** A primeira etapa deste mapeamento se deu pela leitura do título e resumo das publicações científicas de todas as bases de busca escolhidas para o MSL. Os pesquisadores avaliaram as publicações com base nos critérios de inclusão e exclusão (Tabela 3) estabelecidos, e, em caso de dúvidas em relação exclusão de uma determinada publicação, a mesma era mantida na lista de seleção para se analisada na etapa seguinte do processo de seleção.
- **Eliminação por leitura diagonal(2º Filtro):** Nesta etapa, foi realizado a leitura da introdução e da conclusão das publicações, com a finalidade de refinar a seleção preliminar, garantindo que os artigos estejam alinhados às questões de pesquisa. Essa abordagem permitiu uma boa análise dos resultados iniciais, reduzindo a quantidade de resultados para a próxima etapa do MSL. As publicações também foram avaliadas pelos pesquisadores com base nos critérios de inclusão e exclusão (Tabela 3) estabelecidos, e, em caso de dúvidas em relação aceitação ou exclusão de algum artigo, o mesmo era mantido para se analisada na próxima etapa do processo de seleção.
- **Processo de seleção final (3º Filtro):** Esta etapa, atualmente em andamento, se dá pela leitura completa das publicações restantes da lista de seleção, uma vez que a leitura diagonal não é suficiente para determinar se um artigo é relevante para a pesquisa. Aplicando os mesmos critérios de inclusão e exclusão (Tabela 3) nos artigos selecionados no segundo filtro, está etapa conclui o processo de seleção das publicações. As dúvidas de inclusão e exclusão, se houverem, serão discutidas e resolvidas pelos pesquisadores.

4. Resultados

4.1. Resultado do Mapeamento Sistemático da Literatura

A busca inicial nas bases de dados resultou em 376 publicações. A base *Scopus* foi a que mais contribuiu, com 40% do total, seguida pela *ACM* (32%) e *IEEE* (22%). As bases *Wiley* (4%) e *Engineering Village* (2%) tiveram contribuições menores. Após a remoção de 24 artigos duplicados, 352 estudos únicos foram selecionados para a primeira fase de análise.

O processo de seleção iniciou com 352 artigos identificados nas bases de dados. Após a aplicação do primeiro filtro (leitura de títulos e resumos), 44 artigos foram mantidos. A aplicação do segundo filtro (leitura da introdução e conclusão) reduziu este número para 26 artigos. Finalmente, com a leitura completa no terceiro filtro, chegou-se ao conjunto final de 18 artigos que compõem este mapeamento. A Figura 1 ilustra o fluxo completo do processo de seleção dos estudos.

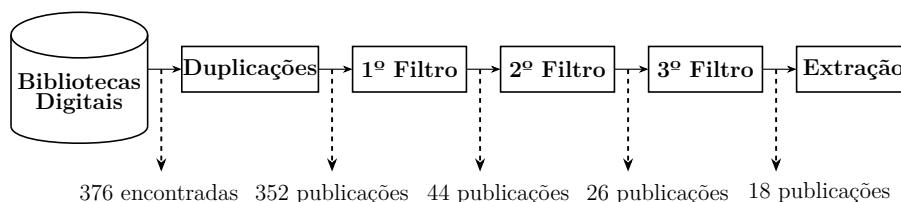


Figure 1. Processo de seleção das publicações

Fonte: Próprio autor

4.2. Análise Qualitativa

A análise dos 18 estudos selecionados permitiu extrair e sintetizar as abordagens utilizadas para o desenvolvimento de interfaces adaptativas com aprendizado de máquina. Os resultados desta análise são apresentados a seguir, organizados de acordo com cada QPs.

4.2.1. QP1: Quais algoritmos de aprendizado de máquina são utilizados?

A análise dos artigos revelou uma gama diversificada de algoritmos de aprendizado de máquina empregados para possibilitar a adaptação de interfaces. A categoria mais prevalente foi a de algoritmos de Classificação, frequentemente utilizados para categorizar usuários, prever suas intenções ou inferir seus estados cognitivos e afetivos. Estudos como o de [Heck et al. 2021] e [Rathnayake et al. 2019] realizaram uma análise comparativa de múltiplos classificadores, incluindo *Random Forest*, *SVM* e *AdaBoost*. Outros trabalhos focaram no uso de modelos específicos, como o *Naive Bayes Classifier* para sistemas de *e-learning* [Oboko et al. 2016] e o *Gradient Boosted Decision Trees (XGBoost)* para o reconhecimento de afeto em robótica assistiva [Shi et al. 2022].

A segunda categoria mais comum foi a de algoritmos de Agrupamento (*Clustering*), usada para segmentar usuários em perfis com comportamentos similares. O *K-means* foi o algoritmo mais comum nesta categoria, aplicado para agrupar usuários em lojas de *e-commerce* [Wasilewski and Kolaczek 2024] e para adaptar layouts de *gamepads* virtuais [Torok et al. 2017]. Outros algoritmos de agrupamento baseados em densidade, como *MeanShift*, também foram empregados para identificar padrões temporais de uso em IHMs industriais [Reguera-Bakhache et al. 2020].

Outras abordagens relevantes, embora menos frequentes, foram identificadas. Modelos sequenciais como Cadeias de *Markov* foram utilizados para prever a próxima ação do usuário em sistemas de recomendação e IHMs [Bouzit et al. 2017, Carrera-Rivera et al. 2024]. A Aprendizagem por Reforço (RL), especialmente com algoritmos como *Q-Learning* e *Monte Carlo Tree Search*, foi proposta para otimizar sequências de adaptações [Gaspar-Figueiredo et al. 2024, Gao et al. 2023]. Finalmente, alguns estudos se basearam em esquemas de previsão heurísticos, como *Most Frequently Used (MFU)* e *Most Recently Used (MRU)*, para adaptação de menus [Vanderdonckt et al. 2019]. A Tabela 7 apresenta um resumo dos algoritmos identificados e os estudos correspondentes.

Tabela 7. Principais Algoritmos de Aprendizado de Máquina Identificados na Literatura

Categoria de Algoritmo	Artigos de Referência
Classificação (<i>SVM</i> , <i>Random Forest</i> , <i>AdaBoost</i> , <i>Naive Bayes</i> , <i>MLP</i> , etc.)	[Gaspar-Figueiredo et al. 2024, Shi et al. 2022, Göbel et al. 2016, Heck et al. 2021, Da Silva et al. 2022, Rathnayake et al. 2019, Oboko et al. 2016]
Agrupamento (Clustering) (<i>K-means</i> , <i>DBSCAN</i> , <i>MeanShift</i> , etc.)	[Torok et al. 2017, Wasilewski and Kolaczek 2024, Rathnayake et al. 2019, Da Silva et al. 2022, Reguera-Bakhache et al. 2020]

Categoria de Algoritmo	Artigos de Referência
Aprendizagem por Reforço (RL) (<i>Q-Learning</i> , MCTS, etc.)	[Gaspar-Figueiredo et al. 2024, Gao et al. 2023, Da Silva et al. 2022]
Modelos Sequenciais/Probabilísticos (Cadeias de <i>Markov</i> , Redes Bayesianas)	[Bouzit et al. 2017, Carrera-Rivera et al. 2024, Da Silva et al. 2022]
Heurísticas de Predição (MFU, MRU, DOI, etc.)	[Vanderdonckt et al. 2019]

4.2.2. QP2: Como os algoritmos são aplicados para personalizar interfaces?

Os estudos selecionados demonstram que a personalização da interface é aplicada de múltiplas formas, sendo a adaptação de layout a mais comum. Esta abordagem envolve a modificação da estrutura visual da interface, como o reposicionamento e redimensionamento de botões em um *gamepad* virtual para se ajustar aos padrões de toque do usuário [Torok et al. 2017]. Em outros casos, a adaptação de layout visa simplificar a interface, ocultando funcionalidades pouco usadas em aplicações web [Rathnayake et al. 2019] ou reorganizando menus para facilitar o acesso em telas de diferentes tamanhos [Vanderdonckt et al. 2019].

A adaptação de conteúdo também é uma estratégia frequente, focada em alterar a informação exibida. Em sistemas de *e-learning*, por exemplo, links para materiais extras são ocultados ou exibidos com base na necessidade prevista do aluno, a fim de gerenciar a carga cognitiva [Oboko et al. 2016]. No contexto de *e-commerce*, a personalização de conteúdo se manifesta através da criação de variantes de UI dedicadas para diferentes segmentos de clientes, alterando desde a página inicial até a apresentação dos produtos [Wasilewski and Kolaczek 2024].

Os contextos de aplicação são diversos, variando de sistemas web de *e-commerce* [Wasilewski and Kolaczek 2024], *e-learning* [Oboko et al. 2016] e mapas cartográficos [Göbel et al. 2016] a ambientes mais especializados como IHMs industriais [Reguera-Bakhache et al. 2020, Carrera-Rivera et al. 2024] e robótica de assistência social [Shi et al. 2022]. A Tabela 8 sumariza as principais aplicações encontradas.

Table 8. Contextos de Aplicação e Tipos de Adaptação

Contexto de Aplicação	Tipo de Adaptação Principal	Artigos
Interfaces Web (Geral)	<i>Layout</i> e Conteúdo	[Da Silva et al. 2022, Rathnayake et al. 2019]
<i>E-commerce</i>	<i>Layout</i> e Conteúdo	[Wasilewski and Kolaczek 2024]
<i>E-learning</i>	Navegação e Apresentação	[Oboko et al. 2016]
IHM Industrial	<i>Layout</i> e Recomendação	[Reguera-Bakhache et al. 2020, Carrera-Rivera et al. 2024]
Robótica Assistiva (SAR)	Percepção de Afeto	[Shi et al. 2022]

Contexto de Aplicação	Tipo de Adaptação Principal	Artigos
Mapas e Navegação	Conteúdo e <i>Layout</i>	[Göbel et al. 2016, Gao et al. 2023]
<i>Gamepad</i> Virtual	<i>Layout</i> (Posição e Tamanho)	[Torok et al. 2017]
<i>Frameworks</i> Teóricos	Todos os tipos	[Bouzit et al. 2017, Vanderdonckt et al. 2019]

4.2.3. QP3: Como os diferentes métodos de coleta de dados influenciam a eficácia da personalização?

Poucos estudos estabelecem uma ligação quantitativa explícita entre o método de coleta de dados e a eficácia da adaptação resultante, mas os que o fazem oferecem *insights* importantes. A maioria dos trabalhos baseia-se na coleta de logs de interação, como o *clickstream* [Wasilewski and Kolaczek 2024, Reguera-Bakhache et al. 2020]. Nesses casos, a eficácia é frequentemente medida pelo impacto da adaptação em métricas de performance ou de negócio. Por exemplo, [Wasilewski and Kolaczek 2024] demonstraram que a adaptação baseada no comportamento de cliques resultou em um aumento de 38,46% na taxa de conversão de uma loja online. De forma similar, [Reguera-Bakhache et al. 2020] mediram a eficácia pela redução no tempo e no número de cliques necessários para completar tarefas em uma IHM industrial.

Em contrapartida, estudos que utilizam dados mais ricos, como rastreamento ocular (*eye tracking*), tendem a medir a eficácia pela acurácia do modelo de aprendizado de máquina em prever as intenções ou preferências do usuário [Göbel et al. 2016, Heck et al. 2021, Gao et al. 2023]. O estudo apresentado por [Heck et al. 2021], por exemplo, mostraram que o uso de múltiplos *features* do olhar com algoritmos de classificação pode prever a preferência do usuário por um conteúdo de vídeo com até 82% de acurácia. Da mesma forma, o trabalho de [Shi et al. 2022] utilizou dados multimodais (áudio, vídeo e logs de jogo) para melhorar a precisão na detecção do estado afetivo de crianças, validando a eficácia do modelo pelo aumento na métrica *AUROC*.

4.2.4. QP4: Quais dispositivos são mais adequados para a aplicação?

A análise dos estudos selecionados indica que as interfaces adaptativas são implementadas em uma variedade de dispositivos, refletindo a expansão do campo. A plataforma predominante é o computador (*desktop/laptop*), sendo o foco de 11 dos 18 estudos analisados, principalmente em aplicações web, sistemas de *e-commerce* e ambientes de simulação [Da Silva et al. 2022, Wasilewski and Kolaczek 2024, Gao et al. 2023, Heck et al. 2021].

Em seguida, os dispositivos móveis, como smartphones e tablets, foram abordados em 6 trabalhos, seja como a plataforma principal da interface adaptativa [Chen et al. 2023, Göbel et al. 2016] ou como um dispositivo de controle para um sistema externo [Torok et al. 2017]. Além disso, é notável a emergência

de dispositivos especializados, identificados em 4 estudos, que incluem robôs de assistência social (SAR) [Shi et al. 2022] e painéis de controle de máquinas industriais [Reguera-Bakhache et al. 2020, Carrera-Rivera et al. 2024]. Essa distribuição demonstra a maturidade da aplicação em plataformas tradicionais e, ao mesmo tempo, a versatilidade e o potencial de expansão da área para novos contextos tecnológicos.

5. Conclusão

Este artigo apresentou um MSL com o objetivo de identificar, analisar e categorizar as principais abordagens de aprendizado de máquina para a criação de interfaces de usuário adaptativas. Através de um processo rigoroso de seleção, 18 estudos foram analisados para responder a questões sobre os algoritmos utilizados, suas formas de aplicação, os métodos de coleta de dados e os dispositivos empregados.

A análise dos resultados revelou um cenário de pesquisa diversificado. Em resposta à QP1, constatou-se que algoritmos de Classificação e Agrupamento (*Clustering*) são as abordagens mais prevalentes, utilizados para segmentar usuários e prever suas intenções. Técnicas mais complexas, como Aprendizagem por Reforço e modelos sequenciais como Cadeias de Markov, embora menos frequentes, demonstram uma tendência de evolução na área. Em relação à QP2, a forma de aplicação mais comum é a adaptação de *layout* e de conteúdo, em contextos que variam desde o *e-commerce* e *e-learning* até ambientes altamente especializados como a robótica assistiva e IHMs industriais. A investigação da QP3 mostrou que, embora a maioria dos estudos colete *logs* de interação, poucos validam quantitativamente a eficácia da adaptação com métricas diretas, uma lacuna importante na área. Por fim, a análise da QP4 indicou uma predominância de aplicações em computadores e dispositivos móveis, mas com uma notável expansão para dispositivos especializados.

As principais contribuições deste trabalho são, portanto: (1) um panorama consolidado das pesquisas publicadas sobre o tema, oferecendo um ponto de partida robusto para novos pesquisadores; (2) a identificação dos algoritmos e estratégias de personalização mais proeminentes, bem como seus contextos de aplicação; e (3) o apontamento de tendências, desafios e lacunas de pesquisa, como a necessidade de mais estudos de validação empírica.

É importante reconhecer as limitações deste estudo. A estratégia de busca, embora abrangente, está sujeita a não capturar todos os trabalhos relevantes devido à variação de terminologias na área. A seleção das bases de dados e o período de tempo analisado também delimitam o escopo dos resultados. Além disso, a categorização dos achados envolve um grau de interpretação por parte dos autores.

Como trabalhos futuros, sugere-se a exploração de algoritmos mais avançados, como modelos de Aprendizagem por Reforço Profundo (*Deep RL*) e Grandes Modelos de Linguagem (*LLMs*), para gerar adaptações mais complexas e conversacionais. Recomenda-se também a realização de mais estudos que validem empiricamente o impacto da adaptação na experiência do usuário com métricas quantitativas. Finalmente, a aplicação de interfaces adaptativas em contextos emergentes, como Realidade Aumentada, Realidade Virtual e dispositivos vestíveis (*wearables*), representa um campo fértil para futuras investigações.

References

- Baranauskas, M. C. C., de Souza, C. S., and Pereira, R. (2012). Grandihc-br: prospecção de grandes desafios de pesquisa em interação humano-computador no brasil. In *Companion Proceedings of the 11th Brazilian Symposium on Human Factors in Computing Systems*, pages 63–64.
- Barbosa, S. and Silva, B. (2010). *Interação humano-computador*. Elsevier Brasil.
- Basili, Rini (Original article, 1994 ed.), V., Caldiera (Original article, 1994 ed.), G., and Rombach (Original article, . e. (2002). *Goal Question Metric (GQM) Approach*. John Wiley & Sons, Ltd.
- Bécue, A., Praça, I., and Gama, J. (2021). Artificial intelligence, cyber-threats and industry 4.0: Challenges and opportunities. *Artificial Intelligence Review*, 54(5):3849–3886.
- Bouzit, S., Calvary, G., Coutaz, J., Chêne, D., Petit, E., and Vanderdonckt, J. (2017). The pda-lpa design space for user interface adaptation. In *11th IEEE International Conference on Research Challenges in Information Science (RCIS)*, pages 353–364. IEEE.
- Browne, D. (2016). *Adaptive user interfaces*. Elsevier.
- Canito, A., Mota, D., Marreiros, G., Corchado, J. M., and Martins, C. (2020). Contextual adaptative interfaces for industry 4.0. In *International Symposium on Distributed Computing and Artificial Intelligence*, pages 149–157. Springer.
- Carrera-Rivera, A., Reguera-Bakhache, D., Larrinaga, F., and Lasa, G. (2024). Exploring the transformation of user interactions to adaptive human-machine interfaces. In *Proceedings of the 29th International Conference on Intelligent User Interfaces*. Association for Computing Machinery.
- Chen, J., Ganguly, B., Kanade, S. G., and Duffy, V. G. (2023). Impact of ai on mobile computing: A systematic review from a human factors perspective. In *Lecture Notes in Computer Science*, volume 14059 LNCS of *Lecture Notes in Computer Science*, pages 24–38. Springer Science and Business Media Deutschland GmbH. Conference paper.
- Da Silva, M. R., Leite, L. L., and Garcia Costa Dos Santos, G. L. (2022). Algorithms for the development of adaptive web interfaces: A systematic literature review. In *2022 IEEE World Conference on Engineering Education (EDUNINE)*, pages 01–08. IEEE.
- Dudley, J. J. and Kristensson, P. O. (2018). A review of user interface design for interactive machine learning. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, 8(2):1–37.
- El Misilmani, H. M. and Naous, T. (2019). Machine learning in antenna design: An overview on machine learning concept and algorithms. In *2019 International Conference on High Performance Computing & Simulation (HPCS)*, pages 600–607. IEEE.
- Gao, J., Reddy, S., Berseth, G., Dragan, A. D., and Levine, S. (2023). Bootstrapping adaptive human-machine interfaces with offline reinforcement learning. In *2023*

IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pages 7523–7530. IEEE.

Gaspar-Figueiredo, D., Fernández-Diego, M., Nuredini, R., Abrahao, S., and Insfran, E. (2024). Reinforcement learning-based framework for the intelligent adaptation of user interfaces. In *Proceedings of the 1st International Workshop on Intelligent User Interfaces for Software Engineering*, pages 40–48. Association for Computing Machinery.

Göbel, F., Giannopoulos, I., and Raubal, M. (2016). The importance of visual attention for adaptive interfaces. In *Proceedings of the 9th ACM International Conference on PErvasive Technologies Related to Assistive Environments*, pages 930–935. Association for Computing Machinery.

Heck, M., Edinger, J., Büinemann, J., and Becker, C. (2021). Exploring gaze-based prediction strategies for preference detection in dynamic interface elements. In *Proceedings of the 2021 International Conference on Advanced Visual Interfaces*, pages 129–139. Association for Computing Machinery.

Hussain, J., Ul Hassan, A., Muhammad Bilal, H. S., Ali, R., Afzal, M., Hussain, S., Bang, J., Banos, O., and Lee, S. (2018). Model-based adaptive user interface based on context and user experience evaluation. *Journal on Multimodal User Interfaces*, 12:1–16.

Kitchenham, B. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering.

Miraz, M. H., Ali, M., and Excell, P. S. (2021). Adaptive user interfaces and universal usability through plasticity of user interface design. *Computer Science Review*, 40:100363.

Oboko, R. O., Maina, E. M., Waiganjo, P. W., Omwenga, E. I., and Wario, R. D. (2016). Designing adaptive learning support through machine learning techniques. In *2016 IST-Africa Conference, IST-Africa 2016*. Institute of Electrical and Electronics Engineers Inc. Conference paper.

Petersen, K., Feldt, R., Mujtaba, S., and Mattsson, M. (2008). Systematic mapping studies in software engineering. *Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering (EASE)*, pages 68–77.

Petticrew, M. and Roberts, H. (2008). Systematic reviews in the social sciences: A practical guide. *Systematic Reviews in the Social Sciences: A Practical Guide*.

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.

Reguera-Bakhache, D., Garitano, I., Uribeetxeberria, R., Cernuda, C., and Zurutuza, U. (2020). Data-driven industrial human-machine interface temporal adaptation for process optimization. In *25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, volume 1, pages 518–525. IEEE.

- Santos, J., Martins, I., and Rodrigues, J. M. (2021). Framework for controlling knx devices based on gestures. In *International Conference on Human-Computer Interaction*, pages 507–518. Springer.
- Shi, Z., Groechel, T. R., Jain, S., Chima, K., Rudovic, O., and Matarić, M. J. (2022). Toward personalized affect-aware socially assistive robot tutors for long-term interventions with children with autism. *ACM Transactions on Human-Robot Interaction*, 11. Cited by: 7.
- Shneiderman, B. and Plaisant, C. (2010). *Designing the user interface: strategies for effective human-computer interaction*. Pearson Education India.
- Todi, K., Bailly, G., Leiva, L., and Oulasvirta, A. (2021). Adapting user interfaces with model-based reinforcement learning. In *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems*, pages 1–13.
- Torok, L., Pelegrino, M., Trevisan, D., Montenegro, A., and Clua, E. (2017). Designing game controllers in a mobile device. In *Lecture Notes in Computer Science*, volume 10289 LNCS of *Lecture Notes in Computer Science*, pages 456–468. Springer Verlag. Conference paper.
- Vanderdonckt, J., Bouzit, S., Calvary, G., and Chêne, D. (2019). Exploring a design space of graphical adaptive menus: Normal vs. small screens. *ACM Transactions on Interactive Intelligent Systems*, 10.
- Wang, Y. (2022). Research on the construction of human-computer interaction system based on a machine learning algorithm. *Journal of Sensors*, 2022:1–11.
- Wasilewski, A. and Kolaczek, G. (2024). One size does not fit all: Multivariable user interface personalization in e-commerce. *IEEE Access*, 12:65570–65582.
- Xu, W., Dainoff, M. J., Ge, L., and Gao, Z. (2023). Transitioning to human interaction with ai systems: New challenges and opportunities for hci professionals to enable human-centered ai. *International Journal of Human-Computer Interaction*, 39(3):494–518.
- Zhou, Z.-H. (2021). *Machine learning*. Springer nature.
- Zhu, M., He, T., and Lee, C. (2020). Technologies toward next generation human machine interfaces: From machine learning enhanced tactile sensing to neuromorphic sensory systems. *Applied Physics Reviews*, 7(3).