



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS FLORIANO
CURSO TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS

VINICIUS ARAUJO LIMA

APRENDIZADO DE MÁQUINA NA MELHORIA DA EXPERIÊNCIA DO USUÁRIO
EM INTERFACES DIGITAIS WEB E MOBILE: UMA REVISÃO SISTEMÁTICA

FLORIANO-PI

2025

VINICIUS ARAUJO LIMA

APRENDIZADO DE MÁQUINA NA MELHORIA DA EXPERIÊNCIA DO USUÁRIO EM
INTERFACES DIGITAIS WEB E MOBILE: UMA REVISÃO SISTEMÁTICA

Trabalho de Conclusão de Curso (artigo científico) apresentado como exigência parcial para obtenção do diploma do Curso de Tecnologia em Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Floriano.

Orientador: Prof. Me. Francisco Eduardo Pires de Moraes

FLORIANO-PI

2025

APRENDIZADO DE MÁQUINA NA MELHORIA DA EXPERIÊNCIA DO USUÁRIO EM INTERFACES DIGITAIS WEB E MOBILE: UMA REVISÃO SISTEMÁTICA

Vinicius Araujo Lima¹
Francisco Eduardo Pires de Moraes²

RESUMO

A criação de interfaces digitais que atendam às expectativas dos usuários ainda é um desafio, já que muitos sistemas apresentam designs complexos e difíceis de usar. Nesse contexto, o aprendizado de máquina surge como uma solução, permitindo que os sistemas se ajustem às preferências e necessidades dos usuários. O objetivo deste trabalho é realizar uma revisão sistemática da literatura sobre a aplicação de algoritmos de aprendizado de máquina na melhoria da experiência do usuário em interfaces digitais web e mobile. A metodologia adotada foi a revisão sistemática da literatura, com a pesquisa baseada em artigos publicados entre 2021 e 2024, coletados nas fontes IEEE Xplore, Web of Science e Scopus. A seleção dos estudos foi realizada em duas fases, com a aplicação de critérios de inclusão e exclusão. Os resultados indicaram que o aprendizado de máquina impacta positivamente a personalização das interfaces, utilizando técnicas como análise de comportamento, rastreamento ocular e segmentação de usuários. Além disso, métricas de desempenho, como taxa de sucesso, tempo de interação e precisão, são essenciais para validar as melhorias. O estudo conclui que o aprendizado de máquina contribui para a criação de interfaces mais intuitivas, alinhadas com as expectativas dos usuários. As lacunas identificadas na pesquisa apontam para a necessidade de futuras investigações sobre a mitigação da sobrecarga cognitiva e o uso de assistentes multimodais, visando o desenvolvimento de interfaces ainda mais adaptáveis e acessíveis.

Palavras-chave: revisão sistemática; aprendizado de máquina; melhoria de interface; experiência do usuário; interface de usuário.

ABSTRACT

The creation of digital interfaces that meet users expectations remains a challenge, as many systems still feature complex and difficult-to-use designs. In this context, machine learning emerges as a promising solution, allowing systems to adjust to users preferences and needs. The goal of this work is to conduct a systematic literature review on the application of machine learning algorithms to improve the user experience in web and mobile digital interfaces. The methodology adopted was the systematic literature review, with research based on articles published between 2021 and 2024, collected from IEEE Xplore, Web of Science, and Scopus. The selection of studies was carried out in two phases, with the application of inclusion and exclusion criteria. The results indicated that machine learning positively impacts the personalization of interfaces, using techniques such as behavior analysis, eye-tracking, and user segmentation. Additionally, performance metrics such as success rate, interaction time, and accuracy are essential for validating improvements. The study concludes that machine learning contributes to the creation of more intuitive interfaces aligned with users expectations. The identified research gaps highlight the need for future investigations

¹ Graduando do curso de Tecnologia em Análise e Desenvolvimento de Sistemas. IFPI - Campus Floriano. caflo.2022114tads08@aluno.ifpi.edu.br.

² Mestre em Engenharia de Software - CESAR School. IFPI - Campus Floriano. professoreduardo.pires@ifpi.edu.br.

into mitigating cognitive overload and utilizing multimodal assistants to develop even more adaptable and accessible interfaces.

Keywords: Systematic review; machine learning; interface improvement; user experience; user interface.

Data de aprovação: 10/01/2025 (data de apresentação do TCC)

1 INTRODUÇÃO

Interface é a porção de um sistema com a qual um usuário interage, seja de forma ativa ou passiva, considerando a interação como um processo de comunicação, a interface pode ser vista como o sistema de comunicação utilizado nesse processo (Prates; Barbosa, 2003). No contexto da interação humano-computador (IHC), a experiência do usuário (*UX*) é um fator crítico para o desenvolvimento de soluções bem-sucedidas, eficientes e agradáveis (Abbas; Ghauth; Ting, 2022). Dessa forma, a *UX* emerge como a qualidade resultante da interação entre o usuário e a interface, influenciando profundamente sua interação com o sistema.

Assim, com o rápido desenvolvimento da tecnologia digital, os usuários esperam uma experiência interativa mais fluida e intuitiva, mas muitos *designs* de interface ainda são complexos e difíceis de implementar (Li *et al.*, 2024). Nesse sentido, para garantir uma interface de alta qualidade, os sistemas frequentemente focam na adaptação como um ponto chave no ciclo de desenvolvimento de interfaces (Miraz; Ali; Excell, 2021). Nesse contexto, a melhoria da interface é essencial para atender às crescentes expectativas dos usuários e garantir uma experiência digital satisfatória.

Diante disso, o aprendizado de máquina está sendo cada vez mais utilizado para melhorar a qualidade da experiência do usuário (Yang; Banovic; Zimmerman, 2018). Assim, o aprendizado de máquina envolve a construção e o estudo de algoritmos que podem aprender e fazer previsões sobre dados, capacitando os sistemas a tomar decisões baseadas em dados históricos (Bishop, 2006). Nesse sentido, o aprendizado de máquina analisa os dados históricos e o comportamento dos clientes para oferecer experiências personalizadas e que, além disso, pode otimizar o processo de *design*, acelerar o desenvolvimento e melhorar a eficiência (Li *et al.*, 2024). Assim, as técnicas de aprendizado de máquina são adequadas para permitir que o sistema adapte a interface de acordo com as preferências e intervenções do usuário (Miraz; Ali; Excell, 2021). Deste modo, a integração do aprendizado de máquina na *UX* não só permite personalizar e otimizar interações, mas também impulsiona a eficiência e a inovação no processo de *design*.

Portanto, mais pesquisas são necessárias para explorar essas áreas, a fim de promover e melhorar a compreensão dos recursos de aprendizado de máquina e resolver questões de *design* relacionadas ao processo de *design* de *UX* (Abbas; Ghauth; Ting, 2022). Para promover avanços contínuos nessa área, os pesquisadores devem aprofundar suas investigações, dada a relevância do desenvolvimento de estudos neste domínio.

Dessa forma, o objetivo deste trabalho é realizar uma revisão sistemática da literatura (RSL) sobre a aplicação de algoritmos de aprendizado de máquina na melhoria da experiência do usuário em interfaces digitais web e mobile, com o propósito de identificar áreas potenciais para investigações futuras. Assim, a RSL pode enriquecer a área em estudo, oferecendo perspectivas valiosas sobre a temática em análise. Este estudo está organizado da seguinte forma: a Seção 2 apresenta o referencial teórico, a Seção 3 explana sobre a metodologia da pesquisa, a Seção 4 aborda os resultados do estudo e por fim, a Seção 5 apresenta a conclusão da pesquisa.

2 REFERENCIAL TEÓRICO

Nesta seção, é examinado os princípios e teorias essenciais relacionados às subseções "Experiência do Usuário em Interfaces Digitais" e "Aprendizado de Máquina na Melhoria da UX" estabelecendo os alicerces necessários para entender-se esses elementos dentro do âmbito do nosso estudo.

2.1 EXPERIÊNCIA DO USUÁRIO EM INTERFACES DIGITAIS

Uma interface é o ponto de interação e comunicação entre dois sistemas, seja entre um usuário e um computador ou entre dois componentes de um sistema, as interfaces servem para facilitar a troca de informações e comandos, tornando a interação mais eficiente e compreensível (Preece, 1994). A experiência do usuário (UX) em interfaces digitais é um aspecto crucial e complexo no desenvolvimento de sistemas modernos. Dessa maneira, uma UX bem projetada não apenas facilita a usabilidade, mas também enriquece a satisfação e o prazer do usuário ao interagir com o sistema (Hassenzahl; Tractinsky, 2006). A UX abrange vários elementos, como usabilidade, *design* visual e eficiência da interface. Assim a usabilidade é definida como a capacidade de um produto ser usado por usuários para alcançar objetivos específicos de maneira eficaz, eficiente e satisfatória (Nielsen, 2012). Logo, uma interface intuitiva que antecipa as necessidades do usuário e oferece feedback claro, pode melhorar significativamente a experiência geral do sistema.

Ademais, outro pilar da UX é o *design* visual, que desempenha um papel vital na primeira impressão que um usuário tem de uma interface. Assim, elementos visuais bem planejados podem atrair e manter a atenção do usuário, enquanto um *design* desordenado ou confuso pode levar à frustração e ao abandono do sistema (Garrett, 2010). Portanto, a estética da interface deve ser harmoniosa e funcional, proporcionando uma experiência agradável sem sacrificar a usabilidade. Bem como, a eficiência da interface é outro aspecto importante da UX, envolvendo a rapidez com que os usuários podem completar suas tarefas. Sistemas que apresentam tempos de resposta rápidos e processos simplificados tendem a ser mais bem recebidos pelos usuários, resultando em uma experiência mais positiva (Krug, 2014).

Entretanto, quando se trata de interfaces *web* e *mobile*, a experiência do usuário pode variar significativamente devido às diferenças nas plataformas. Assim, interfaces *web*, pertencentes a sistemas acessados via navegadores, frequentemente oferecem uma maior complexidade de funcionalidades e espaço para exibir informações, isso permite uma apresentação mais detalhada e rica de conteúdos e interações, o que pode ser vantajoso para tarefas que exigem múltiplas etapas e informações complexas (Marcus, 2005). Por outro lado, interfaces *mobile*, as quais estão presentes em sistemas desenvolvidos para dispositivos móveis, exigem um *design* mais enxuto e focado, adaptado para telas menores e interações por toque, priorizando a simplicidade e a clareza, garantindo que os usuários possam realizar suas tarefas com facilidade (Cole; Rayan; Gomaa, 2024).

Sendo assim, a importância da UX em ambas as plataformas é inegável. Entende-se que, em interfaces *web* uma boa UX pode facilitar a navegação e a descoberta de informações, melhorando a satisfação e a retenção do usuário (Nielsen, 2012). Bem como, um *design* bem planejado para interfaces móveis pode aumentar substancialmente a acessibilidade e a eficiência, proporcionando uma UX mais agradável e produtiva (Harrison; Flood; Duce, 2013). Portanto, entender as especificidades de cada plataforma e aplicar princípios de *design* adequados é essencial para criar interfaces digitais que atendam às necessidades dos usuários de maneira eficaz e eficiente.

Dessa forma, a crescente complexidade e diversidade das interfaces digitais, especialmente entre plataformas *web* e *mobile*, evidenciam a necessidade de meios que

possam melhorar a *UX*. Sendo assim, a adoção de técnicas de aprendizado de máquina surge como um meio de aprimorar a *UX*, ao enviar conteúdos relevantes com base nas suas interações e fornecer recomendações personalizadas, permitindo aprender com hábitos e preferências dos usuários, o que torna a operação mais intuitiva e confortável. (Li *et al.*, 2024).

Sob essa perspectiva, é evidente a necessidade de investigar na literatura como o aprendizado de máquina tem sido empregado para melhorar a *UX* em interfaces digitais, destacando sua relevância na busca por soluções que atendam às demandas cada vez mais diversificadas dos usuários modernos. A integração dessas técnicas traz uma interação mais fluida e intuitiva, além de abrir novas possibilidades no âmbito discutido.

2.2 APRENDIZADO DE MÁQUINA NA MELHORIA DA *UX*

Os algoritmos de aprendizado de máquina têm desempenhado um papel crucial na transformação da *UX*, a aplicação desses algoritmos no *design* de interfaces revela oportunidades significativas para melhorias práticas e soluções inovadoras (Yang; Banovic; Zimmerman, 2018). Sendo assim, aprendizado de máquina é o campo de estudo que dá aos computadores a habilidade de aprender sem serem explicitamente programados, é um programa de computador que melhora seu desempenho em uma tarefa com base em experiências e uma métrica de desempenho (Mitchell, 1997). Diante disso, a utilização de aprendizado de máquina para personalizar e otimizar a interação entre usuários e sistemas digitais tem se tornado cada vez mais importante, proporcionando experiências mais eficazes e intuitivas (Abbas; Ghauth; Ting, 2022).

Ademais, na inovação do *design* de interfaces, os algoritmos de aprendizado de máquina desempenham um papel central. Pois, esses algoritmos têm a capacidade de criar interfaces mais interativas e adaptáveis, respondendo dinamicamente às necessidades dos usuários (Li *et al.*, 2024). Diante disso, a integração de técnicas de *machine learning* possibilita o desenvolvimento de interfaces adaptativas e uma usabilidade universal, assim tais interfaces são capazes de se ajustar dinamicamente às necessidades e preferências individuais dos usuários, promovendo uma interação mais personalizada e eficiente (Miraz; Ali; Excell, 2021).

Como exemplo, a personalização do conteúdo no Facebook, utiliza algoritmos de aprendizado de máquina para melhorar diversos aspectos, como a classificação de postagens, compreensão de conteúdo e detecção de objetos, aumentando significativamente o engajamento na plataforma (Wu *et al.*, 2019). De acordo com Li *et al.* (2019) o uso de aprendizado de máquina para reconhecimento de emoções em interfaces, permite a detecção do estado emocional dos usuários, usando técnicas de processamento de linguagem natural e análise de expressões faciais, sendo assim, possível realizar adaptações nas respostas do sistema para fornecer interações mais empáticas e personalizadas, melhorando assim a satisfação do usuário e aumentando a eficácia das interações do sistema.

Adicionalmente, Klie *et al.* (2018) afirmam que o uso de técnicas de aprendizado de máquina podem adaptar as interfaces para atender às necessidades de usuários com deficiências, ajustando automaticamente o tamanho do texto, o contraste das cores ou fornecendo descrições de áudio para elementos visuais, esta abordagem não só torna as interfaces mais acessíveis, mas também melhora a experiência geral de todos os usuários. Como também, Gazzawe *et al.* (2022) explicam que a integração de algoritmos de aprendizado de máquina em plataformas de *e-learning* permite a personalização dinâmica do conteúdo educacional, adaptando-se automaticamente às necessidades e preferências dos alunos, sendo realizado através da análise contínua dos dados dos usuários, o que possibilita ajustes em tempo real na interface e nas recomendações de aprendizagem.


Portanto, técnicas de inteligência artificial podem ser utilizadas para personalizar e adaptar interfaces digitais, melhorando a *UX* ao reduzir a sobrecarga de informações e tornando a interação mais eficiente e intuitiva (Maes, 1995). Além disso, os avanços nessa área abrem novas oportunidades para a inovação no *design* de interfaces, oferecendo promissores pontos de partida para futuras pesquisas e desenvolvimento (Yang; Banovic; Zimmerman, 2018). Assim, é essencial conduzir mais pesquisas nessas áreas para aprimorar a compreensão dos recursos de aprendizado de máquina e abordar questões de *design* relacionadas ao processo de *design* de *UX* (Abbas; Ghauth; Ting, 2022). Sendo assim, é evidente a necessidade desta pesquisa para investigar como o aprendizado de máquina pode ser empregado em interfaces digitais, visando melhorar a *UX*. Isso proporcionará uma base atualizada sobre as práticas mais recentes e eficazes nesta área.

Ao fundamentar as subseções abordadas com uma base teórica sólida, esta seção estabelece os alicerces essenciais para a análise crítica e interpretação dos resultados da Revisão Sistemática da Literatura (RSL). Essa análise crítica é crucial para uma melhor compreensão das implicações práticas e teóricas da temática em estudo.

3 METODOLOGIA

Para a realização dessa pesquisa, foi utilizado, como procedimento metodológico, a revisão sistemática da literatura (RSL). Foi considerado o estudo de Kitchenham *et al.* (2009) como ponto de partida devido à sua importância na área e sua ampla citação por outros pesquisadores. Foi empregada a estratégia de busca baseada nos termos e conceitos abordados por Kitchenham *et al.* (2009) para identificar estudos relacionados. A Figura 1 apresenta o esquema da metodologia desta pesquisa.

Figura 1 - Etapas da Metodologia da RSL



Fonte: Elaborada pelo autor (2025).

O processo começou com a etapa de planejamento, onde se identificou a necessidade de revisão, especificaram-se os objetivos da RSL e elaborou-se o protocolo de revisão, empregando a ferramenta StArt³. Em seguida, foi feita a etapa de desenvolvimento, onde foram definidas as bases de dados a serem utilizadas e desenvolvida a *string* de busca que foi aplicada. Essa *string* então foi testada e, posteriormente, foram definidos os critérios de inclusão e exclusão para a etapa de seleção dos trabalhos, seguida pela etapa de extração dos dados. Ao final, a síntese dos resultados foi realizada, consolidando e analisando os dados obtidos.

3.1 QUESTÕES DE PESQUISA

Esta subseção apresenta as questões que orientam a pesquisa, formuladas com base nos objetivos do estudo para direcionar a investigação sobre o tema. Assim, foram estabelecidas 03 (três) questões de pesquisa, sendo uma principal e duas secundárias. As questões de pesquisa definidas foram:

3.1.1 Questão de pesquisa principal

Como os algoritmos de aprendizado de máquina podem ser aplicados na melhoria da experiência do usuário em interfaces digitais?

3.1.2 Questões de pesquisa secundárias

- Como os algoritmos de aprendizado de máquina podem ser aplicados para melhorar a experiência do usuário em interfaces digitais *Web* e *Mobile*?
- Como os algoritmos de aprendizado de máquina impactam positivamente a experiência do usuário em interfaces digitais, considerando métricas de desempenho, *feedback* dos usuários ou análise de estudos de caso específicos?

3.2 ESTRATÉGIA DE BUSCA

A definição da estratégia de busca tem a seguinte estrutura: primeiramente, foram identificados os termos importantes para a pesquisa, que são as palavras-chave (Quadro 1), em seguida, essas palavras-chave foram combinadas para formar a *string* de busca (Quadro 2), posteriormente, essa *string* de busca foi inserida nas fontes de dados (Quadro 3). Para a coleta dos estudos, optou-se pela busca nas bases de dados, considerando trabalhos publicados no período de 1º de abril de 2021 a 1º de abril de 2024, em inglês, a escolha do idioma em inglês justifica-se devido à universalidade do idioma, a não inclusão do português se dá pela necessidade de o estudo ser passível de reprodução em diferentes países.

3.2.1 Palavras-chave

As palavras-chave foram selecionadas com base no tema central da revisão e nos conceitos-chave do problema de pesquisa, optando-se pelo inglês devido à universalidade do idioma. Essa escolha é essencial para garantir resultados relevantes e abrangentes, facilitando a identificação de estudos que respondam às questões de pesquisa. O Quadro 1 apresenta as palavras-chave utilizadas nesta pesquisa.

³ Link para a ferramenta StArt, disponível em: <https://www.lapes.ufscar.br/resources/tools-1/start-1>.

Quadro 1 - Palavras-chave

Palavras-chave
<i>Artificial Intelligence, Machine Learning, User Experience, UX, Interface Design, User Interface.</i>

Fonte: Elaborado pelo autor (2025).

3.2.2 *String* de busca

Esta subseção aborda a formulação de termos-chave utilizados para identificar estudos relevantes na RSL. A string foi construída com base nos temas e conceitos-chave do problema de pesquisa, utilizando operadores booleanos (como "AND", "OR") e incluindo sinônimos e variantes para garantir resultados abrangentes e relevantes. O Quadro 2 apresenta a *String* de busca utilizada para esta pesquisa.

Quadro 2 - *String* de busca.

String de Busca
<i>("artificial intelligence" OR "machine learning") AND ("user experience" OR "UX") AND ("interface design" OR "user interface")</i>

Fonte: Elaborado pelo autor (2025).

3.2.3 Fontes de dados

As fontes de dados são os locais de onde foram coletadas os trabalhos para a realização da RSL. As fontes selecionadas para este estudo foram escolhidas com base em sua relevância científica na área de informática. Foram priorizadas fontes reconhecidas pela comunidade acadêmica por sua alta qualificação e pela acessibilidade dos trabalhos. O Quadro 3 apresenta as Fontes de Dados que foram utilizadas para esta pesquisa.


Quadro 3 - Fontes de dados

Fontes de Busca	URLs
IEEE Xplore	http://www.ieeexplore.ieee.org/Xplore
Web of Science	https://www.webofscience.com/
Scopus	http://www.scopus.com/

Fonte: Elaborada pelo autor (2025).

Após aplicar a string de busca nas fontes de dados, obteve-se um total de 264 trabalhos, conforme mostrado na Figura 2, sendo possível observar que a busca resultou na identificação de 137 artigos na fonte de dados IEEE Xplore, 63 artigos na fonte de dados Web of Science e 64 artigos na fonte de dados Scopus. A Figura 2 mostra a distribuição dos artigos coletados em cada fonte de dados.

Figura 2 - Resultado da busca nas fontes de dados selecionadas



Fonte: Elaborado pelo autor (2025).

3.3 CRITÉRIOS DE INCLUSÃO E EXCLUSÃO

Com o intuito de responder às questões de pesquisa foram incluídos e excluídos estudos considerados relevantes e irrelevantes para a revisão sistemática.

3.3.1 Critérios de inclusão

- 1) Trabalhos que tratem da aplicação de algoritmos de aprendizado de máquina para melhorar a experiência do usuário em interfaces digitais *Web* e *Mobile*.
- 2) Trabalhos que apresentem resultados sobre o impacto positivo dos algoritmos de aprendizado de máquina na melhoria da experiência do usuário, como métricas de desempenho, *feedback* dos usuários ou análise de estudos de caso específicos.

3.3.2 Critérios de exclusão

- 1) Artigos completos que não foram publicados de 2021 a 2024 na língua inglesa.
- 2) Artigos que não se enquadram com os critérios de inclusão da pesquisa.
- 3) Artigos incompletos e dissertações.

3.4 SELEÇÃO DOS ESTUDOS

A etapa de seleção de estudos é fundamental em uma RSL, pois garante a relevância e a qualidade dos artigos analisados. Essa etapa é dividida em duas fases: a seleção preliminar (1º filtro), na qual são avaliados títulos, palavras-chave e resumos dos estudos coletados, aplicando-se critérios de inclusão e exclusão, com o suporte da ferramenta StArt. A ferramenta StArt visa facilitar a condução da revisão, sendo bem avaliada por estudantes de pós-graduação por sua eficácia e benefícios em comparação a outras soluções disponíveis (LAPES, [s.d.]). A segunda fase é a seleção final (2º filtro), que consiste na leitura completa dos artigos selecionados no 1º filtro, permitindo uma análise mais detalhada e a aplicação dos critérios de inclusão e exclusão, para determinar os estudos que serão considerados na apresentação dos resultados finais da revisão.


3.4.1 Qualidade dos estudos

Segundo Nakagawa *et al.* (2017), a qualidade da RSL está intrinsecamente ligada à qualidade dos estudos primários selecionados. A avaliação da qualidade é realizada por meio de formulários de extração de dados que abordam aspectos metodológicos dos estudos, conforme preconizado por Kitchenham *et al.* (2009). De acordo com Higgins *et al.* (2019), a interpretação dos resultados é influenciada pela inclusão de estudos validados e características relevantes. Para qualificar os estudos, foi adotado o método de leitura em pares proposto por Nakagawa *et al.* (2017), no qual um pesquisador seleciona os artigos e o outro revisa pelo menos um terço das amostras, resolvendo conflitos por consenso.

4 RESULTADOS

Nesta seção, são apresentados os resultados da RSL. A Figura 3 apresenta um resumo da quantidade de trabalhos coletados e selecionados em cada etapa da revisão.

Figura 3 - Quantidade de trabalhos coletados e selecionados ao longo da revisão



Fonte: Elaborado pelo autor (2025).

Desse modo, após a realização da seleção preliminar, dos 264 trabalhos coletados, 41 trabalhos foram selecionados para a fase seguinte. Já na seleção final, após a leitura completa dos artigos selecionados inicialmente, 15 artigos foram selecionados para a síntese dos resultados, de acordo com os critérios de inclusão e exclusão estabelecidos para esta pesquisa. Vale ressaltar que um mesmo artigo pode atender a mais de um critério de inclusão. Dos 15 artigos selecionados, 15 atendem ao Critério de Inclusão 1 (CI1) e 12 ao Critério de Inclusão 2 (CI2). O Quadro 4 apresenta os artigos escolhidos de acordo com os critérios de inclusão.

Quadro 4 - Artigos da análise final do estudo

ID	Título do Artigo	Autor	Fonte de Dados	Ano	CI
A1	The use of computer vision and data mining in	(Bercik <i>et al.</i> , 2022)	IEEE	2022	CI1 e CI2

	obtaining subconscious user experience				
A2	Personalized Instant Messaging UI Design for Elderly	(Heree; Ujir; Hipiny, 2022)	IEEE	2022	CI1 e CI2
A3	An Evaluation Framework for User Experience Using Eye Tracking, Mouse Tracking, Keyboard Input, and Artificial Intelligence: A Case Study	(Souza <i>et al.</i> , 2022)	Web of Science	2022	CI1 e CI2
A4	Application and Analysis of Artificial Intelligence Graphic Element Algorithm in Digital Media Art Design	(Tian, 2022)	Scopus	2022	CI1
A5	Benchmarking Neural Networks-Based Approaches for Predicting Visual Perception of User Interfaces	(Bakaev <i>et al.</i> , 2022)	Scopus	2022	CI1 e CI2
A6	Analyzing Factors Influencing Adoption of AI in E-Commerce UI/UX Design Using TAM	(Mailangkay; Satyabodhi; Halim, 2023)	IEEE	2023	CI1
A7	Usability Evaluation of Virtual Communication Tools Using UX/UI Design and ML Techniques	(Singh <i>et al.</i> , 2023)	IEEE	2023	CI1 e CI2
A8	UI/UX Design for Online Learning approach by Predictive Student Experience	(Chaganti <i>et al.</i> , 2023)	IEEE	2023	CI1 e CI2
A9	MARLMUI: Multi-Agent Reinforcement Learning Approach in Mobile Adaptive User Interface	(Vidmanov; Alfimtsev, 2023)	IEEE	2023	CI1 e CI2
A10	Impact of Technological Developments on Customer Satisfaction in Online Banking	(Mahajan, 2023)	IEEE	2023	CI1 e CI2

A11	Process Mining IPTV Customer Eye Gaze Movement Using Discrete-Time Markov Chains	(Chen <i>et al.</i> , 2023)	Web of Science	2023	CI1 e CI2
A12	Exploring the transformation of user interactions to adaptive human-machine interfaces	(Carrera-Rivera <i>et al.</i> , 2023)	Scopus	2023	CI1 e CI2
A13	Multi-Modal Accessibility Enhancement for Diverse User Groups	(Khan <i>et al.</i> , 2024)	IEEE	2024	CI1
A14	Mobile User Interface Adaptation Based on Usability Reward Model and Multi-Agent Reinforcement Learning	(Vidmanov; Alfimtsev, 2024)	Web of Science	2024	CI1 e CI2
A15	Functional Framework for Multivariant E-Commerce User Interfaces	(Wasilewski, 2024)	Scopus	2024	CI1 e CI2

Fonte: Elaborado pelo autor (2025).

A seguir, as subseções 4.1 e 4.2 apresentam uma análise dos trabalhos selecionados apresentados no Quadro 4, tratando respectivamente das questões de pesquisa 1 e 2 da revisão.

4.1 COMO O APRENDIZADO DE MÁQUINA PODE SER APLICADO PARA MELHORAR A UX EM INTERFACES DIGITAIS WEB E MOBILE?

Os resultados da pesquisa mostraram que os domínios de aplicação do aprendizado de máquina em interfaces se manifestam em diversas áreas e atividades relacionadas à interação dos usuários. O Quadro 5 apresenta as aplicabilidades do aprendizado de máquina em interfaces digitais.

Quadro 5 - Aplicabilidades de aprendizado de máquina em interfaces

Área de aplicação de ML em interfaces digitais	Aplicabilidade
Personalização de Interface e Design Adaptativo	Um dos trabalhos investiga a incorporação de inteligência artificial em interfaces de comércio eletrônico, utilizando o Technology Acceptance Model (TAM) para alinhar o design <i>UI/UX</i> com as expectativas dos usuários. A IA é usada para adaptar a interface conforme preferências do consumidor, melhorando a personalização e a eficiência em plataformas de e-commerce (Mailangkay; Satyabodhi; Halim, 2023).

	Já outro apresenta uma abordagem de Aprendizado por Reforço Multiagente (MARLMUI) para adaptar interfaces de usuário móveis. Utiliza Processos de Decisão de Markov (MDP) e Dec-POMDP para otimizar a interação, ajustando a interface dinamicamente às necessidades dos usuários (Vidmanov; Alfimtsev, 2023). Um outro exemplo propõe um modelo de recompensa de usabilidade (UR) para interfaces móveis adaptativas, usando aprendizado por reforço multi-agente, empregando algoritmos como Independent Q-Learning (IQL) e Multi-Agent Deep Deterministic Policy Gradient (MADDPG), avaliando os valores de ação dos agentes para melhorar a usabilidade e adaptação da interface (Vidmanov; Alfimtsev, 2024). Já outro trabalho foca na personalização de interfaces em comércio eletrônico, utilizando algoritmos de aprendizado de máquina, como o K-means, para analisar o comportamento do usuário e ajustar a apresentação e conteúdo das interfaces conforme as necessidades dos clientes. O K-means foi usado para segmentar usuários em grupos distintos, permitindo personalizações mais eficazes nas interfaces de e-commerce (Wasilewski, 2024). Esse outro trabalho já investiga interfaces adaptativas (AUIs) utilizando cadeias de Markov e o Modelo Oculto de Markov para prever ações do usuário e fornecer recomendações personalizadas. O estudo visa melhorar a <i>UX</i> em sistemas interativos através de personalizações dinâmicas baseadas no comportamento dos usuários, utilizando as cadeias de Markov para analisar sequências de interações e prever as próximas ações, enquanto o Modelo Oculto de Markov permite a criação de modelos mais complexos para uma adaptação ainda mais precisa (Carrera-Rivera <i>et al.</i>, 2023).
Análise de UX com Visão Computacional	Como exemplo, essa pesquisa utiliza ferramentas de visão computacional, como rastreamento ocular com a câmera Tobii X2-30 e leitura facial com a ferramenta FaceReader 7, para analisar a experiência implícita do usuário em dois sites, é comparado designs existentes e novos para identificar problemas e áreas de melhoria no processo de compra (Bercik <i>et al.</i>, 2022). Já outro explora o uso de rastreamento ocular em um aplicativo de vídeo sob demanda (VoD). Utiliza uma Cadeia de Markov de Tempo Discreto (DTMC) para analisar a movimentação ocular dos usuários e avaliar a eficácia do design da interface (Chen <i>et al.</i>, 2023).
Análise de Dados de Satisfação e Interação do Usuário	Este trabalho foca na importância do design de <i>UI/UX</i> em plataformas de aprendizado online, aplicando Naive Bayes, SVM e KNN para analisar dados de satisfação do usuário. O objetivo é identificar fatores

	que influenciam a experiência e usabilidade de plataformas educacionais (Chaganti <i>et al.</i>, 2023). Já esse outro trabalho propõe um framework (AIT2-UX) que combina rastreamento ocular, rastreamento de mouse e algoritmos de inteligência artificial, como Árvores de Decisão (DT), Perceptron Multicamadas (MLP) e Máquinas de Vetores de Suporte (SVM), para avaliar a <i>UX</i> de sistemas de informação, e assim categorizar perfis de desempenho para compreender a interação do usuário (Souza <i>et al.</i>, 2022).
Tecnologias Inclusivas e Acessibilidade	De exemplo, este estudo foca em criar interfaces de usuário personalizadas para idosos, usando algoritmos de aprendizado de máquina como SVM (Support Vector Machine) e Naive Bayes para prever preferências e ajustar interfaces de dispositivos móveis de acordo com características específicas dos idosos. Gerando uma inclusão digital ao adaptar interfaces para idosos (Heree; Ujir; Hipiny, 2022). Esse outro estudo desenvolve um aplicativo móvel focado em acessibilidade multimodal, usando EasyOCR, modelo BART, algoritmo Weighted TF-IDF e algoritmos de correção de cores para atender usuários com deficiências visuais, dislexia e daltonismo, assim extraíndo e convertendo texto em fala, para melhorar a legibilidade e ajustar contrastes de cores (Khan <i>et al.</i>, 2024).
Previsão de Percepção Visual e transferência de estilo	Um exemplo é este trabalho que explora a aplicação de redes neurais convolucionais (CNNs) para prever a percepção estética de interfaces web. A pesquisa busca prever a atratividade de interfaces e identificar elementos que contribuem para a complexidade visual (Singh <i>et al.</i>, 2023). Já esse outro investiga a previsão da percepção visual de interfaces de usuário (UIs) na web usando redes neurais artificiais (ANN) e convolucionais (CNN). A pesquisa foca na análise de dimensões subjetivas como estética e complexidade para melhorar o design de interfaces digitais (Bakaev <i>et al.</i>, 2022). Esse outro trabalho já explora a transferência de estilo em design de interfaces móveis, aplicando algoritmos específicos de aprendizado de máquina para criar interfaces esteticamente agradáveis e funcionais, reduzindo a carga cognitiva dos usuários (Tian, 2022).
Análise de Sentimentos	Nessa área, esse trabalho analisa o impacto de inovações tecnológicas nos serviços bancários online, utilizando análise estatística e análise de sentimentos. A pesquisa identifica fatores de qualidade que influenciam a experiência do usuário, como segurança e personalização, e destaca a importância de feedback contínuo (Mahajan, 2023).

Ao analisar o Quadro 5, podemos observar que o aprendizado de máquina pode ser aplicado em diversas áreas para melhorar a experiência do usuário em interfaces digitais, desde a personalização e adaptação dinâmica até a análise de sentimentos. Essas abordagens demonstram como a inteligência artificial pode ser utilizada para entender, prever e atender às necessidades dos usuários de maneira eficiente e inovadora.

Na área de personalização de interface e design adaptativo, os trabalhos destacam o uso de algoritmos para ajustar interfaces conforme as preferências dos usuários, promovendo experiências mais relevantes e intuitivas. Um estudo utilizou o Technology Acceptance Model (TAM) para alinhar o design *UI/UX* às expectativas do consumidor por meio da personalização automática em plataformas de e-commerce, incorporando inteligência artificial nesse processo (Mailangkay; Satyabodhi; Halim, 2023). Outro trabalho apresentou uma abordagem de aprendizado por reforço multiagente (MARLMUI) para interfaces móveis, ajustando dinamicamente as interfaces às necessidades dos usuários com base em Processos de Decisão de Markov (MDP) e Dec-POMDP (Vidmanov; Alfimtsev, 2023). De forma complementar, outro estudo propôs um modelo de recompensa de usabilidade (UR) para aprimorar a adaptação de interfaces móveis usando aprendizado por reforço, foram aplicados algoritmos como Independent Q-Learning (IQL) e Multi-Agent Deep Deterministic Policy Gradient (MADDPG), para investigar o impacto nas métricas de usabilidade, permitindo a adaptação em tempo real com base nas interações do usuário (Vidmanov; Alfimtsev, 2024).

Em outro estudo, o algoritmo K-means foi utilizado para segmentar usuários de uma loja online, criando clusters com características distintas. Isso permitiu ajustar automaticamente o conteúdo e a apresentação da interface, melhorando a experiência do usuário em plataformas de e-commerce (Wasilewski, 2024). Já outro trabalho investigou interfaces adaptativas (AUIs), utilizando cadeias de Markov para prever ações dos usuários e fornecer recomendações personalizadas, assim o modelo de Cadeia de Markov foi empregado para analisar sequências de interações, permitindo que o sistema adapte às suas sugestões com base no comportamento anterior do usuário, além disso, o Modelo Oculto de Markov foi mencionado como uma abordagem para criar modelos mais complexos, demonstrando como sistemas interativos podem se adaptar às preferências dos usuários em tempo real, melhorando a experiência do usuário (Carrera-Rivera *et al.*, 2023).

Conectando-se à ideia de adaptação, a área de análise de *UX* com visão computacional utiliza ferramentas para compreender interações implícitas dos usuários. Um estudo explorou o uso de rastreamento ocular e leitura facial, especificamente a câmera Tobii X2-30 e a ferramenta FaceReader 7, para analisar a experiência em sites, comparando designs existentes e novos para propor melhorias no processo de compra assim foi possível monitorar a atenção visual dos participantes e suas reações emocionais durante a interação com os sites (Bercik *et al.*, 2022). Outro trabalho aplicou Cadeias de Markov de Tempo Discreto (DTMC) para investigar a movimentação ocular em aplicativos de vídeo sob demanda, avaliando a eficácia do design de interfaces em sistemas IPTV (Chen *et al.*, 2023). Essas técnicas destacam como é possível extrair insights valiosos sobre a interação do usuário de forma não invasiva, fornecendo informações para otimizações contínuas.

Na análise de dados de satisfação e interação do usuário, os estudos utilizaram algoritmos supervisionados para extrair informações valiosas sobre a experiência do usuário. Um estudo utilizou Naive Bayes, SVM e KNN para identificar fatores que influenciam a usabilidade de plataformas educacionais, com base em dados de satisfação dos usuários (Chaganti *et al.*, 2023). Outro trabalho desenvolveu o framework AIT2-UX, que combina rastreamento ocular e de mouse com algoritmos de inteligência artificial, incluindo Árvores de Decisão (DT), Perceptron Multicamadas (MLP) e Máquinas de Vetores de Suporte (SVM), para categorizar perfis de desempenho e entender a interação do usuário (Souza *et al.*, 2022).

Essas abordagens mostram como técnicas de aprendizado de máquina podem ir além da coleta de feedback direto, analisando padrões de interação para melhorar a *UX*.

Seguindo essa linha de melhoria inclusiva, os trabalhos na área de tecnologias inclusivas e acessibilidade destacam a importância de adaptar interfaces para públicos específicos. Um estudo desenvolveu interfaces móveis personalizadas para idosos, utilizando SVM e Naive Bayes para prever preferências e ajustar o design de dispositivos móveis, promovendo inclusão digital (Heree; Ujir; Hipiny, 2022). Outro estudo criou um aplicativo voltado para acessibilidade multimodal, que utiliza EasyOCR, modelo BART, algoritmo Weighted TF-IDF e algoritmos de correção de cores para atender usuários com deficiências visuais, dislexia e daltonismo, melhorando a legibilidade e promovendo uma interação mais acessível (Khan *et al.*, 2024).

Avançando para a previsão de percepção visual e transferência de estilo, os trabalhos investigaram como redes neurais podem melhorar a estética e funcionalidade de interfaces. Um estudo usou CNNs para prever a atratividade de interfaces web e identificar elementos que influenciam sua complexidade visual (Singh *et al.*, 2023). De forma semelhante, outro trabalho analisou a percepção visual utilizando ANN e CNNs, focando em dimensões como estética e complexidade para melhorar o design digital (Bakaev *et al.*, 2022). Outro exemplo, investiga a aplicação de algoritmos de aprendizado de máquina na transferência de estilo para o design de interfaces móveis demonstrando como técnicas de aprendizado de máquina podem ser utilizadas para criar interfaces que são tanto esteticamente agradáveis quanto funcionais (Tian, 2022).

Por fim, no âmbito de análise de sentimentos, um estudo analisou o impacto de inovações tecnológicas nos serviços bancários online, utilizando análise estatística e de sentimentos para investigar fatores que influenciam a *UX*, como segurança e personalização, o estudo aplicou algoritmos de aprendizado de máquina, na área análise de sentimentos para categorizar feedback dos clientes, e métodos preditivos para avaliar a satisfação do usuário com base em dados históricos (Mahajan, 2023).

4.2 COMO O APRENDIZADO DE MÁQUINA IMPACTA A *UX* EM INTERFACES DIGITAIS, CONSIDERANDO MÉTRICAS, FEEDBACK OU ESTUDOS DE CASO?

O aprendizado de máquina impacta positivamente a *UX* em interfaces digitais ao aplicar métricas e feedbacks que comprovam como essas tecnologias identificam padrões de uso e guiam melhorias na interação dos usuários. A relação entre métricas e o comportamento dos usuários evidencia diretamente os benefícios do aprendizado de máquina. Por exemplo, no estudo que utilizou métricas de visão computacional, como mapas de calor e a duração total de fixação, foi demonstrado que o aprendizado de máquina permitiu direcionar o olhar dos usuários para áreas relevantes da interface, melhorando sua eficiência. Além disso, a leitura facial revelou uma melhora na valência emocional dos usuários, evidenciando maior satisfação durante a interação com a interface (Bercik *et al.*, 2022).

Outro estudo comprovou o impacto positivo do aprendizado de máquina ao personalizar interfaces para idosos com base em métricas como precisão e recall. Utilizando algoritmos como Naive Bayes (MNB) e Support Vector Machine (SVM), o estudo mostrou que o MNB, com maior precisão, permitiu ajustes mais eficazes às emoções dos usuários. Essa abordagem, aliada a feedbacks qualitativos, revelou que a personalização aumentou a taxa de sucesso e reduziu o tempo de conclusão de tarefas, evidenciando a eficácia do aprendizado de máquina na criação de interfaces mais inclusivas e adaptadas (Heree, Ujir e Hipiny, 2022).

A ferramenta T2-UXT também demonstrou como as métricas comprovam o impacto positivo do aprendizado de máquina na *UX*. Coletando dados sobre movimentos do mouse,

rastreamento ocular e entradas de teclado, o aprendizado de máquina foi capaz de identificar dificuldades específicas de navegação no site da Receita Federal do Brasil. Após ajustes baseados nessas métricas, a experiência de usuário tornou-se mais fluida e eficiente, validando o uso dessas tecnologias para melhorias contínuas (Souza *et al.*, 2022). No mesmo sentido, o modelo Webthetics DNN demonstrou como o aprendizado de máquina pode prever percepções estéticas e melhorar a *UX* ao utilizar métricas como tempo de execução de tarefas, taxa de sucesso e avaliações subjetivas (Bakaev *et al.*, 2022).

Em plataformas de aprendizado online, o impacto do aprendizado de máquina foi evidenciado por métricas como precisão e taxa de erro. Algoritmos com alta precisão e baixa taxa de erro aumentaram a eficiência na execução de tarefas, enquanto análises qualitativas destacaram a importância de interfaces intuitivas e agradáveis. Esse estudo provou como o aprendizado de máquina pode guiar ajustes eficazes e melhorar a experiência do usuário (Singh *et al.*, 2023). Além disso, modelos GOMS e KLM reforçaram esse impacto ao medir o tempo de execução de tarefas, a taxa de sucesso e o número de interações, permitindo identificar pontos de fricção e ajustar interfaces para torná-las mais eficientes e intuitivas (Vidmanov; Alfimtsev, 2023).

No setor bancário online, as métricas derivadas de interações dos usuários, como cliques, trilhas de navegação e tempo gasto em atividades, comprovaram como o aprendizado de máquina pode ajustar elementos de usabilidade e segurança. Feedbacks contínuos alimentaram modelos que dinamicamente alinharam as interfaces às expectativas dos clientes, promovendo uma experiência mais satisfatória e eficiente (Mahajan, 2023). Métricas baseadas em rastreamento ocular também comprovaram os benefícios do aprendizado de máquina em interfaces web de IPTV. O tempo de fixação em áreas de interesse (AOIs) e a análise de movimentos oculares revelaram preferências e dificuldades dos usuários, resultando em interfaces mais claras e atraentes após ajustes baseados nos dados coletados (Chen *et al.*, 2023).

No e-commerce, o impacto positivo do aprendizado de máquina foi comprovado por meio de dados de clickstream e segmentação de usuários com algoritmos como K-means. Esses dados permitiram personalizar interfaces para diferentes grupos de usuários, aumentando a taxa de conversão e o valor médio dos pedidos. Variantes de interfaces testadas em ambientes reais validaram essas melhorias, evidenciando como métricas quantitativas podem guiar decisões eficazes de design (Wasilewski, 2024).

Sistemas de recomendação adaptáveis também mostraram como o aprendizado de máquina, utilizando métricas como precisão, recall e MRR, prioriza corretamente opções mais relevantes para os usuários. Feedbacks implícitos complementam essas métricas, permitindo ajustes contínuos e aprimoramentos que melhoraram a navegação (Carrera-Rivera *et al.*, 2023). Outra pesquisa reforçou a relevância do aprendizado de máquina, demonstrando uma precisão maior do Naive Bayes em plataformas de aprendizado online. Feedbacks dos usuários mostraram que 75,6% já haviam abandonado sites devido a experiências de *UX* insatisfatórias. A coleta de métricas como taxa de abandono e satisfação foi fundamental para identificar problemas e implementar melhorias estéticas e de navegação, aumentando a retenção de usuários e validando a eficácia de ajustes baseados em dados (Chaganti *et al.*, 2023).

Por fim, o aprendizado por reforço foi aplicado para otimizar interações em interfaces digitais. Métricas como tempo de busca e tempo de seleção de elementos evidenciaram que essas tecnologias superam abordagens estáticas ao identificar pontos de fricção e permitir ajustes para tornar a navegação mais fluida e eficaz. Esses resultados comprovam que o aprendizado de máquina, combinado a métricas mensuráveis e feedbacks dinâmicos, promove melhorias contínuas e aperfeiçoa a experiência do usuário (Vidmanov; Alfimtsev, 2024). Assim, através dessas métricas, feedbacks e casos de uso, podemos perceber que o

aprendizado de máquina impacta positivamente a *UX* nas interfaces digitais, validando e aprimorando a interação dos usuários com elas.

5 CONCLUSÃO

A pesquisa identificou que o aprendizado de máquina tem se consolidado como uma ferramenta essencial para aprimorar a experiência do usuário em interfaces digitais web e mobile. Esta revisão evidenciou que a aplicação de técnicas de aprendizado de máquina permitem não apenas a personalização e adaptação dinâmica de interfaces, mas também garante a acessibilidade e a otimização da interação.

Nesse contexto, os estudos analisados destacam a atuação em áreas como design adaptativo, visão computacional, análise de satisfação, acessibilidade, previsão de percepção visual e análise de sentimentos do usuário. Entre os algoritmos mais utilizados destacam-se o Naive Bayes aplicado na análise de fatores que influenciam a usabilidade e a previsão de preferências, o Support Vector Machine (SVM) utilizado na análise comportamental para identificar padrões complexos, o K-Nearest Neighbors (KNN) que auxilia na previsão de ações e na melhoria da experiência do usuário. Além disso, o modelo matemático Cadeias de Markov foi amplamente utilizado para modelar interações dos usuários e ajustar recomendações com base no seu comportamento sequencial. Outro modelo utilizado foi o modelo de Redes Neurais Convolucionais (CNNs), que desempenha um papel fundamental na previsão da percepção visual e na análise de imagens, sendo capaz de identificar elementos visuais que influenciam a atratividade das interfaces.

Complementando, entre as métricas quantitativas mais abordadas estão, precisão, recall, taxa de erro, tempo de execução de tarefas, taxa de abandono, taxa de sucesso, tempo de fixação, mapas de calor, taxa de conversão, e tempo de interação, que são essenciais para avaliar o desempenho dos sistemas, medindo a exatidão das previsões, a capacidade de identificar casos positivos, os erros cometidos e a eficiência no cumprimento de tarefas. Além disso, feedbacks de usuários e análises emocionais oferecem insights qualitativos importantes sobre a satisfação e engajamento, complementando as métricas objetivas. A combinação dessas métricas permite ajustes contínuos nas interfaces, melhorando a personalização e alinhamento com as expectativas dos usuários.

Dessa forma, o aprendizado de máquina não apenas melhora a funcionalidade das interfaces, mas também contribui para a criação de experiências estéticas e emocionalmente satisfatórias. Esta pesquisa se mostra relevante por evidenciar como essas tecnologias podem ser aplicadas para personalizar e otimizar as interações do usuário, promovendo interfaces mais intuitivas e alinhadas às suas necessidades. Ao explorar o impacto do aprendizado de máquina no design de interfaces digitais, a pesquisa contribui para a evolução de sistemas mais eficazes, acessíveis e centrados no usuário.

A partir da revisão da literatura realizada, identificaram-se lacunas de pesquisa que podem ser exploradas em trabalhos futuros, como o uso de aprendizado de máquina na detecção e mitigação da sobrecarga cognitiva em interfaces, identificando sinais como hesitação ou interações repetitivas e ajustando o design em tempo real para evitar frustrações do usuário. Outra lacuna encontrada é a integração de assistentes virtuais multimodais, capazes de alternar entre comandos de voz, gestos e toque com base no contexto do usuário, adaptando a interação levando em conta fatores como barulho ambiente ou incapacidade de usar as mãos, proporcionando assim uma interação mais eficiente. Essas abordagens podem tornar as interfaces mais acessíveis, adaptáveis e alinhadas às necessidades dos usuários.

REFERÊNCIAS

ABBAS, A.; GHAUTH, K.; TING, C.-Y. User experience design using machine learning: A systematic review. **IEEE access**, v. 10, p. 51501–51514, 2022. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9770797>. Acesso em: 26 abr. 2024.

BAKAEV, M. *et al.* Benchmarking neural networks-based approaches for predicting visual perception of user interfaces. In: **International Conference on Human-Computer Interaction**. Cham: Springer International Publishing, 2022. p. 217-231. Disponível em: https://link.springer.com/chapter/10.1007/978-3-031-05643-7_14. Acesso em: 18 de set. 2024.

BERCIK, J. *et al.* The use of computer vision and data mining in obtaining subconscious user experience. In: **2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)**. IEEE, 2022. p. 1-5. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9988203>. Acesso em 18 de set. 2024.

BISHOP, C.; NASRABADI, N. **Pattern recognition and machine learning**. New York: Springer, 2006.

CARRERA-RIVERA, A. *et al.* Exploring the transformation of user interactions to Adaptive Human-Machine Interfaces. In: **Proceedings of the XXIII International Conference on Human Computer Interaction**. 2023. p. 1-7. Disponível em: <https://dl.acm.org/doi/abs/10.1145/3612783.3612807>. Acesso em: 18 de set. 2024.

CHAGANTI, K. *et al.* UI/UX Design for Online Learning Approach by Predictive Student Experience. In: **2023 7th International Conference on Electronics, Communication and Aerospace Technology (ICECA)**. IEEE, 2023. p. 794-799. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10395866>. Acesso em: 18 de set. 2024.

CHEN, Z. *et al.* Process Mining IPTV Customer Eye Gaze Movement Using Discrete-Time Markov Chains. **Algorithms**, v. 16, n. 2, p. 82, 2023. Disponível em: <https://www.mdpi.com/1999-4893/16/2/82>. Acesso em: 18 de set. 2024.

COLE, A.; RAYAN, F.; GOMAA, A.-R. ‘Post Op’ A novel Smartphone Application for Post operative recovery in Elective Arthroplasty- a review of patient experiences. **Osteoarthritis and cartilage**, v. 32, n. 6, p. 774–775, 2024. Disponível em: [https://www.oarsijournal.com/article/S1063-4584\(24\)01051-3/abstract](https://www.oarsijournal.com/article/S1063-4584(24)01051-3/abstract). Acesso em: 7 mai. 2024.

GARRETT, J. **The Elements of User Experience: User-Centered Design for the Web and Beyond**. Berkeley, CA: New Riders, 2010.

GAZZAWE, F. *et al.* [Retracted] The Role of Machine Learning in E-Learning Using the Web and AI-Enabled Mobile Applications. **Mobile Information Systems**, v. 2022, n. 1, p. 3696140, 2022. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1155/2022/3696140>. Acesso em: 12 mai. 2024.

HARRISON, R.; FLOOD, D.; DUCE, D. Usability of mobile applications: literature review and rationale for a new usability model. **Journal of interaction science**, v. 1, n. 1, p. 1–16, 2013. Disponível em: <https://link.springer.com/article/10.1186/2194-0827-1-1>. Acesso em: 27 abr. 2024.

HASSENZAHN, M.; TRACTINSKY, N. User experience-a research agenda. **Behaviour & information technology**, v. 25, n. 2, p. 91–97, 2006. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01449290500330331>. Acesso em: 11 mai. 2024.

HEREE, N.; UJIR, H.; HIPINY, I. Personalized Instant Messaging UI Design for Elderly. In: **2022 OITS International Conference on Information Technology (OCIT)**. IEEE, 2022. p. 73-78. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10053772>. Acesso em: 18 de set. 2024.

HIGGINS, J. *et al.* **Cochrane handbook for systematic reviews of interventions**. John Wiley & Sons, 2019.

KHAN, M. *et al.* Multi-Modal Accessibility Enhancement for Diverse User Groups. In: **2024 IEEE International Conference for Women in Innovation, Technology & Entrepreneurship (ICWITE)**. IEEE, 2024. p. 440-445. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10502974>. Acesso em: 18 de set. 2024.

KITCHENHAM, B. *et al.* Systematic literature reviews in software engineering—a systematic literature review. **Information and software technology**, v. 51, n. 1, p. 7-15, 2009. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0950584908001390>. Acesso em: 20 abr. 2024.

KLIE, J.-C. *et al.* The inception platform: Machine-assisted and knowledge-oriented interactive annotation. Em: **Proceedings of the 27th international conference on computational linguistics: system demonstrations**. Santa Fe, New Mexico: Dongyan Zhao, 2018. p. 5–9. Disponível em: <https://aclanthology.org/C18-2002>. Acesso em: 16 abr. 2024.

KRUG, S. **Don't make me think, Revisited. A Common Sense Approach to Web and Mobile Usability**. Berkeley, CA: New Riders, 2014.

LAPES. **StArt**. Disponível em: <https://www.lapes.ufscar.br/resources/tools-1/start-1>. Acesso em: 11 jun. 2024.

LI, X. *et al.* User interaction interface design and innovation based on artificial intelligence technology. **Journal of Theory and Practice of Engineering Science**, v. 4, n. 03, p. 1–8, 2024. Disponível em: <https://centuryscipub.com/index.php/jtpes/article/view/507>. Acesso em: 2 abr. 2024.

MAES, P. Agents that Reduce work and information Overload. Em: **Readings in Human–Computer Interaction**. [s.l.] Elsevier, 1995. p. 811–821. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/B9780080515748500844>. Acesso em: 24 de mai. 2024.

MAHAJAN, R. Impact of Technological Developments on Customer Satisfaction in Online Banking. In: **2023 IEEE International Conference on ICT in Business Industry & Government (ICTBIG)**. IEEE, 2023. p. 1-6. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10456305>. Acesso em: 18 de set. 2024.

MAILANGKAY, A.; SATYABODHI, R.; HALIM, E. Analyzing Factors Influencing Adoption of AI in E-Commerce UI/UX Design Using TAM. In: **2023 IEEE 3rd International Conference on Social Sciences and Intelligence Management (SSIM)**. IEEE, 2023. p. 41-45. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10468833>. Acesso em: 18 de set. 2024.

MARCUS, A. User interface design's return on investment: Examples and statistics. In: **Cost-justifying usability**. Morgan Kaufmann, 2005. p. 17-39. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/B978012095811550002X>. Acesso em: 27 de mai. 2024.

MIRAZ, M.; ALI, M.; EXCELL, P. Adaptive user interfaces and universal usability through plasticity of user interface design. **Computer science review**, v. 40, n. 100363, p. 100363, 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1574013721000034>. Acesso em: 2 mai. 2024.

MITCHELL, T. Does machine learning really work? **AI magazine**, v. 18, n. 3, p. 11–11, 1997. Disponível em: <https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1303>. Acesso em: 20 mai. 2024.

NAKAGAWA, E. et al. **Revisão sistemática da literatura em engenharia de software: teoria e prática**. Elsevier Brasil, 2017.

NIELSEN, J. Usability 101: Introduction to usability. **Nielsen Norman Group**. [s.l.], 2012. Disponível em: <https://www.nngroup.com/articles/usability-101-introduction-to-usability/>. Acesso em: 3 jun. 2024.

PRATES, R.; BARBOSA, S. Avaliação de interfaces de usuário—conceitos e métodos. Em: **Jornada de Atualização em Informática do Congresso da Sociedade Brasileira de Computação, Capítulo**. sn, 2003.p. 28. Disponível em: https://homepages.dcc.ufmg.br/~rprates/ge_vis/cap6_vfinal.pdf. Acesso em: 2 abr. 2024.

PREECE, J. **Human-Computer Interaction: Concepts And Design**. [s.l.] Addison Wesley Longman, 1994.

SINGH, K. *et al.* Usability Evaluation of Virtual Communication Tools Using UX/UI Design and ML Techniques. In: **2023 OITS International Conference on Information Technology (OCIT)**. IEEE, 2023. p. 855-860. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10431279>. Acesso em: 18 de set. 2024.

SOUZA, K. *et al.* An evaluation framework for user experience using eye tracking, mouse tracking, keyboard input, and artificial intelligence: A case study. **International Journal of**

Human–Computer Interaction, v. 38, n. 7, p. 646-660, 2022. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/10447318.2021.1960092>. Acesso em: 18 de set. 2024.

TIAN, H. Application and analysis of artificial intelligence graphic element algorithm in digital media art design. **Mobile Information Systems**, v. 2022, n. 1, p. 6946616, 2022. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1155/2022/6946616>. Acesso em: 18 de set. 2024.

VIDMANOV, D.; ALFIMTSEV, A. MARLMUI: Multi-agent reinforcement learning approach in Mobile Adaptive User Interface. In: **2023 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE)**. IEEE, 2023. p. 1-5. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10086785>. Acesso em: 18 de set. 2024.

VIDMANOV, D.; ALFIMTSEV, A. Mobile User Interface Adaptation Based on Usability Reward Model and Multi-Agent Reinforcement Learning. **Multimodal Technologies and Interaction**, v. 8, n. 4, p. 26, 2024. Disponível em: <https://www.mdpi.com/2414-4088/8/4/26>. Acesso em: 18 de set. 2024.

WASILEWSKI, A. Functional framework for multivariant e-commerce user interfaces. **Journal of Theoretical and Applied Electronic Commerce Research**, v. 19, n. 1, p. 412-430, 2024. Disponível em: <https://www.mdpi.com/0718-1876/19/1/22>. Acesso em: 18 de set. 2024.

WU, C.-J. et al. Machine learning at facebook: Understanding inference at the edge. Em: **2019 IEEE international symposium on high performance computer architecture (HPCA)**. IEEE, 2019. p. 331-344. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8675201>. Acesso em: 20 mai. 2024.

YANG, Q.; BANOVIC, N.; ZIMMERMAN, J. Mapping machine learning advances from hci research to reveal starting places for design innovation. Em: **Proceedings of the 2018 CHI conference on human factors in computing systems**. New York, NY: ACM, 2018. p. 1-11. Disponível em: <https://dl.acm.org/doi/abs/10.1145/3173574.3173704>. Acesso em: 14 mai. 2024.