

Avaliação Human-Centered de Sistemas de Recomendação Baseados em IA: Uma Análise Comparativa entre Domínios

Ana Beatriz Maciel Nunes¹, Márcia Sampaio Lima¹

¹ Universidade do Estado do Amazonas (UEA)
Av. Darcy Vargas, 1.200, Parque 10 de Novembro – Manaus, AM - Brazil

abmn.snf23@uea.edu.br, msllima@uea.edu.br

Abstract. Introduction & objective: This study analyzes how AI-based recommender systems are perceived from a human-centered perspective, considering the influence of the domain of use and the emotional cost of errors on the desirability of explanations. **Methodology:** A comparative qualitative investigation was conducted between Spotify (entertainment) and Duolingo (education), structured using the RE4HCAI framework and complemented by empathy maps. **Results:** Results indicate that AI perception is mediated by the context of use and the emotional responses associated with errors, rather than solely by the degree of technical transparency. We conclude that explainability should be calibrated according to the domain and the emotional impact of the interaction.

Keywords: AI-based recommender systems; human-centered AI; explainable AI; emotional cost of error; requirements engineering.

Resumo. Introdução e objetivo: Este estudo analisa como sistemas de recomendação baseados em IA são percebidos sob uma perspectiva centrada no humano, considerando a influência do domínio de uso e do custo emocional do erro na desejabilidade de explicações. **Metodologia:** Foi conduzida uma investigação qualitativa comparativa entre Spotify (entretenimento) e Duolingo (educação), estruturada a partir do framework RE4HCAI e complementada por mapas de empatia. **Resultados:** Os resultados indicam que a percepção da IA é mediada pelo contexto de uso e pelas respostas emocionais associadas ao erro, e não apenas pelo grau de transparência técnica. Conclui-se que a explicabilidade deve ser calibrada conforme o domínio e o impacto emocional da interação.

Palavras-chave: sistemas de recomendação baseados em IA; inteligência artificial centrada no humano; inteligência artificial explicável; custo emocional do erro; engenharia de requisitos.

1. Introdução

Sistemas de recomendação baseados em Inteligência Artificial (IA) estão presentes em grande parte das plataformas digitais utilizadas cotidianamente, como serviços de *streaming* musical, redes sociais e aplicativos educacionais [Raza et al. 2024]. Esses sistemas analisam dados de comportamento e preferências para sugerir conteúdos personalizados, influenciando diretamente a experiência dos usuários.

Com o avanço das técnicas de aprendizado de máquina, esses sistemas tornaram-se progressivamente mais sofisticados e precisos. No entanto, esse aumento de desempenho frequentemente ocorre às custas de maior opacidade dos modelos, dificultando a compreensão de como as recomendações são geradas [Mohamed et al. 2025]. Essa falta de transparência levanta questões que vão além das métricas técnicas tradicionais, como precisão e taxa de acertos.

Nesse contexto, a área de *Explainable Artificial Intelligence* (XAI) tem emergido para tornar sistemas de IA mais compreensíveis [Minh et al. 2022]. Estudos sobre *design* de explicações indicam que a utilidade dessas explicações depende do contexto e das necessidades do usuário, sendo frequentemente orientadas a tarefas específicas, como compreender erros ou resultados inesperados [Liao et al. 2020].

Quando se observam diferentes domínios de aplicação, percebe-se que o impacto de uma recomendação inadequada pode variar significativamente. Estudos recentes sobre a influência das emoções em sistemas de recomendação indicam que elementos afetivos, como *algorithm appreciation* (apreciação algorítmica) e *algorithm fatigue* (fadiga algorítmica), mediam a relação entre as percepções do sistema e a intenção de uso continuado [Zhang et al. 2025]. Essa diferença sugere que a necessidade de explicações e a percepção de confiança no sistema são mediadas tanto pelo contexto de uso quanto pelas respostas emocionais dos usuários.

Apesar do crescimento das discussões sobre explicabilidade em IA, ainda existem lacunas na compreensão de como a percepção dos usuários sobre sistemas de recomendação varia conforme o domínio de aplicação e o custo emocional associado aos erros. Em particular, poucos estudos comparam, de forma sistemática, sistemas de domínios distintos sob uma perspectiva centrada no humano, integrando requisitos técnicos e dimensões experienciais. A literatura em Engenharia de Requisitos para IA tem avançado com *frameworks* como o RE4HCAI, que propõe uma abordagem estruturada para elicitação de requisitos considerando necessidades do usuário, do modelo, explicabilidade e tratamento de erros [Ahmad et al. 2023] [Santos et al. 2025]. Entretanto, sua aplicação em análises comparativas entre domínios ainda é incipiente. Diante desse cenário, esta pesquisa tem como objetivo geral investigar como sistemas de recomendação baseados em inteligência artificial são percebidos pelos usuários, mais especificamente no contexto de plataformas de entretenimento e educação.

Para atingir esse objetivo, foram definidos quatro objetivos específicos: (1) Identificar os requisitos centrados no humano presentes em sistemas de recomendação de diferentes domínios, utilizando o *framework* RE4HCAI; (2) Modelar a experiência do usuário em cada domínio por meio de mapas de empatia, capturando aspectos emocionais e comportamentais; (3) Comparar os achados entre os dois domínios selecionados: entretenimento (Spotify) e educação (Duolingo), contrastando contextos hedônicos e avaliativos; (4) Triangular os requisitos técnicos com os perfis experienciais para compreender como o contexto modula a percepção da IA. Assim, foi conduzida uma investigação qualitativa e exploratória em três etapas: (i) aplicação do *Checklist* RE4HCAI [Santos et al. 2025]; (ii) construção de mapas de empatia; e (iii) triangulação interpretativa entre requisitos técnicos e perfis experienciais. Como resultado, foram identificadas diferenças na percepção de explicabilidade e nas necessidades emocionais dos usuários entre os dois domínios, confirmando que a percepção da IA é impactada pelo contexto de uso e pelo

custo emocional do erro.

2. Referencial teórico e trabalhos relacionados

Sistemas de recomendação têm sido utilizados para apoiar a tomada de decisão em ambientes digitais, tradicionalmente baseados em técnicas como filtragem colaborativa e filtragem baseada em conteúdo [Ricci et al. 2021]. Com o avanço da Inteligência Artificial, esses sistemas passaram a incorporar técnicas de aprendizado profundo e modelos mais complexos, ampliando sua capacidade de personalização e previsão, mas também aumentando os desafios relacionados à interpretabilidade e transparência [Gheewala et al. 2025].

Nesse cenário, a *Explainable Artificial Intelligence* (XAI) emerge como abordagem para mitigar a opacidade de modelos baseados em IA, buscando tornar suas decisões mais compreensíveis e auditáveis [Vilone and Longo 2020]. A literatura destaca que a evolução para arquiteturas mais complexas demanda mecanismos que permitam compreender o funcionamento técnico dos modelos e seus impactos na experiência dos usuários.

No âmbito da Engenharia de Requisitos, o *framework* RE4HCAI propõe uma estrutura para elicitacão e análise de requisitos centrados no humano em sistemas baseados em IA, contemplando dimensões como necessidades do usuário, modelo, dados, *feedback*, controle e tratamento de erros [Ahmad et al. 2023]. O *Checklist* RE4HCAI foi aplicado em contexto educacional por Santos et al. [Santos et al. 2025], evidenciando sua utilidade como instrumento sistemático de reflexão e análise sobre requisitos de sistemas de IA.

Além disso, abordagens de design centrado no usuário, como os mapas de empatia, permitem modelar dimensões subjetivas da experiência, organizando percepções, emoções e motivações dos usuários [Gray et al. 2010]. No contexto específico de sistemas recomendadores, estudos recentes de avaliação indicam que métricas tradicionais de precisão são insuficientes para capturar a qualidade percebida da recomendação, sendo necessário considerar múltiplas dimensões como diversidade, serendipidade, equidade e satisfação do usuário [Duricic et al. 2023, Jadon and Patil 2024]. Esses trabalhos reforçam que a avaliação de recomendadores deve ir além do desempenho técnico e incorporar fatores relacionados à experiência e percepção do usuário.

Diferentemente dos trabalhos mencionados, que abordam sistemas recomendadores sob perspectivas técnicas ou metodológicas específicas, esta pesquisa integra o *framework* RE4HCAI e mapas de empatia para analisar comparativamente a percepção da IA em sistemas de recomendação utilizados em domínios distintos, considerando o papel do contexto de uso e do custo emocional do erro na desejabilidade de explicações e na experiência do usuário.

3. Metodologia

A pesquisa adota uma abordagem qualitativa e exploratória, orientada por uma perspectiva *human-centered* e sociotécnica [Shneiderman 2020], com o objetivo de analisar como sistemas de recomendação baseados em inteligência artificial são percebidos pelos usuários, mais especificamente no contexto de plataformas de entretenimento e educação. Conforme ilustra a Figura 1, o delineamento metodológico desta pesquisa foi estruturado em três etapas complementares: (i) análise de requisitos orientada pelo *framework* RE4HCAI [Ahmad et al. 2023], feita através do *Checklist* RE4HCAI [Santos et al. 2025] (ii) mode-

lagem da experiência do usuário por meio de mapas de empatia, utilizados como instrumento complementar de eliciação, e (iii) triangulação interpretativa dos achados.




Figura 1. Fluxo metodológico da pesquisa.

Na primeira etapa, foram selecionados dois aplicativos com domínios de utilização distintos: Spotify¹ (entretenimento) e Duolingo² (educação). Ambos os sistemas empregam IA de forma central: o Spotify, para a curadoria de *playlists* e a recomendação musical; o Duolingo, para recomendar exercícios e sequenciar o conteúdo de aprendizado. A seleção buscou contrastar contextos de uso em que a percepção do usuário e o impacto das recomendações podem variar. A análise qualitativa de ambos foi conduzida utilizando o *framework* RE4HCAI [Ahmad et al. 2023] e o *Checklist* RE4HCAI [Santos et al. 2025] como lentes conceituais para a identificação e estruturação de requisitos centrados no humano. Ambos permitiram guiar a observação sistemática, focando em dimensões como a transparência das recomendações, o controle oferecido ao usuário, os mecanismos de *feedback* e as potenciais consequências de uma recomendação inadequada. O preenchimento inicial do guia analítico baseado no RE4HCAI, o *Checklist* RE4HCAI, foi realizado pelo primeiro autor e validado em ciclos de discussão com o segundo autor, especialista na área de Engenharia de Requisitos para IA (RE4AI). Como resultado desta etapa, foi produzido um diagnóstico comparativo dos dois aplicativos a partir do *Checklist* RE4HCAI, no qual cada dimensão do *framework* foi analisada quanto à sua presença, classificada como atendida, parcialmente atendida ou não atendida, permitindo identificar lacunas e oportunidades de melhoria sob uma perspectiva centrada no humano. Para a classificação dos itens como “atendida”, “parcialmente atendida” ou “não atendida”, adotou-se um critério operacional baseado na presença de evidências observáveis na interface, documentação pública ou comportamento funcional do sistema. Considerou-se “atendida” quando havia evidência clara e consistente da dimensão analisada; “parcialmente atendida” quando a evidência era limitada, condicional ou implícita; e “não atendida” quando não foram identificadas evidências nas fontes examinadas.

Na segunda etapa, objetivando capturar dimensões subjetivas e emocionais da interação dos usuários com os aplicativos, foram elaborados mapas de empatia [Gray et al. 2010] para cada sistema. Este instrumento de *design* centrado no usuário foi utilizado para estruturar, de forma reflexiva, as perspectivas do usuário. Os mapas

¹<https://www.spotify.com>

²<https://www.duolingo.com>

Tabela 1. Spotify e Duolingo sob as lentes do *framework* RE4HCAI.

Dimensão - RE4HCAI	Spotify (Entretenimento)	Duolingo (Aprendizado)
<i>User Needs</i>	Descobrir músicas; experiência contínua.	Aprender; progressão visível; gamificação.
<i>Model Needs</i>	Modelo opaco; adaptação vista apenas nos resultados.	Modelo pouco claro; adaptação percebida por meio de erros/acertos.
<i>Data Needs</i>	Dados usados de forma genérica; vieses não evidentes.	Respostas e desempenho usados; compreensão limitada.
<i>Feedback & Control</i>	<i>Feedback</i> simples (curtir/pular); controle fácil.	<i>Feedback</i> constante (pontuação/streak); controle sobre o ritmo de aprendizado.
<i>Explainability & Trust</i>	Explicabilidade implícita; confiança pela adequação.	Progresso explícito; confiança com base em métricas visíveis.
<i>Errors & Failures</i>	Erros de baixo impacto emocional; falhas invisíveis.	Erros geram frustração; impacto alto na motivação.

foram construídos a partir da análise das *interfaces* de usuário, das funcionalidades e dos fluxos de interação dos sistemas, organizando as inferências em seções próprias do instrumento: o que o usuário vê, ouve, pensa e sente, diz e faz, além de suas dores e ganhos. O processo de preenchimento e refinamento dos mapas seguiu o mesmo ciclo de validação entre os autores descrito na etapa anterior. Como resultado desta etapa, foram criados perfis experienciais que serão utilizados na análise integrada.

Por fim, na terceira etapa, realizou-se uma triangulação interpretativa entre os artefatos produzidos nas duas etapas precedentes. Esta triangulação consistiu no confronto sistemático entre os requisitos identificados pela lente do RE4HCAI e os perfis experienciais modelados nos mapas de empatia. O processo buscou articular as perspectivas de *design* do sistema (requisitos) e a vivência do usuário (experiência), identificando congruências, tensões e lacunas. A discussão resultante, apresentada na Seção 4, foca em implicações para o *design* de interação de sistemas de recomendação, considerando a influência do contexto de uso, o custo emocional do erro e a explicabilidade percebida.

4. Resultados e discussões

Esta seção apresenta os resultados obtidos a partir da aplicação do procedimento metodológico adotado e os discute à luz da literatura. A organização da seção segue quatro eixos analíticos descritos nos próximos parágrafos.

1 - A aplicação do *framework* RE4HCAI aos sistemas de recomendação do Spotify e do Duolingo foi realizada com base no *Checklist* RE4HCAI. A Tabela 1 resume os resultados comparativos da aplicação do *Checklist* aos dois sistemas. Os resultados gerados a partir de cada ítem do *Checklist* estão disponíveis para acesso ³.

Os resultados evidenciam uma dissociação entre a complexidade técnica dos sistemas e sua percepção pelos usuários. Embora ambos empreguem modelos de IA, a experiência do usuário é mediada por camadas de interação que tornam a tecnologia mais ou menos visível conforme o domínio e o objetivo do sistema. Esse achado está alinhado

³<https://figshare.com/s/6399dd6a0c82403c38b7>

às discussões de Arrieta et al. (2020) , que defendem que a explicabilidade em IA deve ser contextual e orientada ao usuário, e não um reflexo direto da complexidade técnica do modelo.

No Spotify, a IA opera de forma predominantemente invisível. A percepção do usuário concentra-se nos resultados, como *playlists* alinhadas aos seus gostos e estados emocionais, e não nos mecanismos que as geram. A adaptação do sistema é inferida a partir da recorrência de acertos percebidos, o que sustenta a confiança sem exigir explicações explícitas. Já no Duolingo, a IA assume um papel mais visível, uma vez que erros e acertos são elementos centrais do processo de aprendizagem. A adaptação algorítmica torna-se perceptível por meio da variação de dificuldade e da progressão apresentada, ainda que seus fundamentos técnicos permaneçam pouco compreendidos. Essa diferença reforça a ideia de que a visibilidade da IA não é uma propriedade intrínseca do sistema, mas um efeito do contexto de uso e das consequências percebidas da interação.

2 - Modelagem da experiência do usuário com mapas de empatia: Para compreender as dimensões subjetivas da experiência com sistemas de recomendação, foram desenvolvidas duas personas [Cooper et al. 2004] representativas, que serviram de base para a construção de mapas de empatia. Essa abordagem complementa a análise estruturada fornecida pelo *framework* RE4HCAI, permitindo capturar aspectos emocionais, motivacionais e contextuais que influenciam diretamente a forma como a IA é percebida durante a interação.

A persona **Júlia** representa uma usuária frequente do Spotify de 22 anos, que utiliza o aplicativo diariamente como companhia para estudos e trabalho. Ela valoriza descobertas musicais personalizadas, utiliza *playlists* para regulação emocional e busca uma experiência contínua e fluida, sem interrupções. Seus principais motivadores incluem encontrar músicas que expressem suas emoções e compartilhar descobertas com amigos.

A persona **Rafael** (28 anos, analista de sistemas) representa um usuário do Duolingo motivado por objetivos de aprendizagem e progressão profissional. Ele utiliza o aplicativo diariamente no transporte, valoriza *feedbacks* rápidos e mantém uma rotina consistente para preservar seu *streak* (sequência diária). Sua motivação está associada à gamificação, ao reconhecimento do progresso e à busca por fluência básica em inglês.

Com base nessas personas, foram elaborados mapas de empatia detalhados (Figuras 2 e 3) que capturam não apenas comportamentos observáveis, mas também pensamentos, emoções, dores e ganhos experimentados durante a interação com cada sistema.



Figura 2. Mapa de empatia do Spotify (Júlia)



Figura 3. Mapa de empatia do Duolingo (Rafael)

No caso do Spotify, o mapa de empatia (Figura 2) revela uma experiência fortemente associada ao domínio hedônico. A música é percebida como parte da identidade do usuário e como um recurso para regulação emocional e concentração. O sistema é utilizado de forma contínua, muitas vezes em segundo plano, o que reforça a invisibilidade da IA enquanto mecanismo técnico. A percepção do algoritmo ocorre quase exclusiva-

mente por meio dos resultados apresentados, como *playlists* consideradas “adequadas” ao humor ou ao momento, e não por explicações ou controles explícitos. As principais dores relatadas concentram-se na repetição de recomendações e na sensação de pouca transparência sobre os critérios do algoritmo; entretanto, essas limitações não comprometem significativamente a experiência, pois o custo emocional do erro é baixo e facilmente ignorável.

No Duolingo, por sua vez, o mapa de empatia (Figura 3) aponta para uma experiência predominantemente utilitária e avaliativa. O objetivo educacional do sistema é claramente percebido, assim como sua lógica adaptativa baseada em erros e acertos. A gamificação desempenha um papel central na motivação do usuário, mas também introduz elementos de pressão, como a manutenção do *streak* e a exposição constante do desempenho. Diferentemente do Spotify, o erro no Duolingo possui alto impacto emocional, estando associado à frustração, à quebra de ritmo e à autoavaliação negativa. Além disso, apesar do feedback constante e explícito, os usuários percebem limitações relacionadas à repetição excessiva de exercícios e à falta de explicações mais aprofundadas, especialmente em conteúdos gramaticais.

A análise comparativa dos mapas de empatia reforça os achados obtidos com o RE4HCAI ao evidenciar que a percepção da IA ocorre majoritariamente por meio da interação, do *feedback* e do impacto emocional dos erros, e não pelo entendimento técnico do modelo ou dos dados utilizados. Em ambos os sistemas, aspectos como coleta de dados, vieses e funcionamento interno do modelo permanecem invisíveis ao usuário final. Contudo, os efeitos dessa invisibilidade variam conforme o domínio de uso: no Spotify, ela contribui para uma experiência fluida e pouco intrusiva; no Duolingo, a maior explicitação do desempenho intensifica a carga cognitiva e o custo emocional da interação.

3 - Raciocínio analítico sobre os sistemas de recomendação: A triangulação entre os artefatos gerados pelo uso do *framework* RE4HCAI e da geração dos mapas de empatia permite elaborar um raciocínio analítico sobre como sistemas de recomendação são percebidos e avaliados sob uma perspectiva centrada no humano. Os resultados indicam que a qualidade da experiência não está diretamente associada ao grau de transparência técnica da IA, mas sim à forma como seus efeitos se manifestam na interação cotidiana.

Esses resultados dialogam diretamente com Liao et al. (2020), que argumentam que explicações em Explainable Artificial Intelligence (XAI) devem responder a necessidades práticas e contextuais dos usuários. Os autores identificaram, a partir da análise de perguntas reais de usuários a sistemas de IA, que as explicações desejadas são majoritariamente orientadas a tarefas específicas (como compreender um erro) e não ao funcionamento interno do modelo. No presente estudo, observa-se que os usuários do Duolingo demandam justamente esse tipo de explicação prática para correção de erros gramaticais, enquanto usuários do Spotify não manifestam necessidade equivalente.

O presente estudo avança essa discussão ao evidenciar que a desejabilidade de explicações depende do domínio e do custo emocional do erro. Em contextos hedônicos, como o Spotify, explicações detalhadas tendem a ser desnecessárias, corroborando o modelo de confiança em IA proposto por Afroogh et al. (2024), no qual a confiabilidade percebida e o baixo custo do erro sustentam a confiança mesmo na ausência de transparência técnica. Em contextos avaliativos, como o Duolingo, explicações que auxiliem

na correção de erros podem ser particularmente relevantes, pois estudos sobre o uso de IA em ambientes educacionais indicam que emoções negativas, como ansiedade e frustração, influenciam diretamente a experiência, motivação e engajamento dos alunos com os sistemas [Vistorte et al. 2024]. Esses achados sugerem que a experiência emocional do erro assume papel central na forma como os usuários percebem e utilizam sistemas de IA educacionais, reforçando a necessidade de explicações que considerem tanto aspectos cognitivos quanto emocionais da interação.

Implicações práticas dos achados: Os achados desta análise apontam implicações relevantes para o planejamento (projeto) e a avaliação de sistemas de recomendação baseados em IA. Primeiramente, indicam que a explicabilidade deve ser calibrada em função do domínio de uso e do custo emocional do erro. Em contextos de baixo risco, como o entretenimento, a invisibilidade controlada da IA pode favorecer a fluidez da experiência. Em contextos utilitários e avaliativos, como o aprendizado, a transparência deve ser cuidadosamente balanceada para evitar sobrecarga cognitiva e efeitos motivacionais adversos.

Os achados também reforçam que aspectos emocionais e motivacionais devem ser tratados como requisitos centrais no *design* de sistemas recomendadores. Conforme destacado pelo relatório de Bauer et al. (2024), métricas técnicas isoladas são insuficientes para capturar a qualidade percebida da experiência. Elementos como custo emocional do erro, sensação de controle e impacto do *feedback* devem integrar explicitamente os processos de avaliação e *design* dos sistemas baseados em IA.

Por fim, o estudo evidencia a importância de abordagens de avaliação centradas no humano que combinem *frameworks* estruturados, como o RE4HCAI, com métodos qualitativos capazes de capturar a vivência do usuário. A triangulação entre esses instrumentos contribui para uma compreensão mais abrangente da experiência com sistemas de IA, apoiando o desenvolvimento de soluções não apenas tecnicamente eficazes, mas também alinhadas às necessidades, expectativas e limites humanos.

5. Conclusões

Este estudo teve como objetivo analisar como sistemas de recomendação baseados em inteligência artificial são percebidos pelos usuários, mais especificamente no contexto de plataformas de entretenimento e educação. A pesquisa buscou compreender de que forma as dimensões do *framework* RE4HCAI, incluindo necessidades do usuário, necessidades do modelo, necessidades de dados, mecanismos de *feedback* e controle, explicabilidade e tratamento de erros, se manifestam na experiência cotidiana com sistemas recomendadores.

Os resultados indicaram que a percepção da IA não está diretamente associada ao grau de transparência técnica do modelo, mas sim ao impacto que suas decisões exercem sobre a experiência do usuário. Observou-se que, em contextos hedônicos, como o entretenimento, a invisibilidade da IA tende a favorecer uma experiência fluida, uma vez que o custo emocional do erro é baixo. Já em contextos avaliativos, como o aprendizado, o erro assume maior peso emocional, tornando explicações potencialmente mais relevantes, desde que calibradas para não intensificar a pressão ou a frustração. Esses achados reforçam a necessidade de uma abordagem contextual para a explicabilidade em sistemas de recomendação, alinhada às discussões sobre *Human-Centered Explainable AI*.

Como limitações do estudo, destacam-se: (1) a análise concentrou-se em apenas dois sistemas, o que pode restringir a generalização dos achados para outros domínios de aplicação; (2) a avaliação foi conduzida por dois pesquisadores, o que pode introduzir vieses interpretativos, ainda que ciclos de validação tenham sido realizados para mitigá-los; e (3) a aplicação do *framework* RE4HCAI e a construção das personas basearam-se em análises interpretativas das interfaces e funcionalidades observadas.

Como trabalhos futuros, sugere-se a ampliação da investigação para outros domínios de aplicação, incluindo sistemas de recomendação de maior risco ou impacto social, como saúde, finanças e recrutamento. Estudos experimentais, entrevistas ou questionários com usuários poderão validar e aprofundar as relações identificadas entre o domínio de uso, o custo emocional do erro e a desejabilidade de explicações. Adicionalmente, investigações que explorem diferentes configurações de explicabilidade adaptativa podem contribuir para o desenvolvimento de sistemas recomendadores mais sensíveis às dimensões emocionais, contextuais e éticas da experiência humana.

Agradecimentos

Agradecemos à UEA, por meio do Programa de Produtividade Acadêmica 01.02.011304.026472/2023-87 pelo apoio ao desenvolvimento desta pesquisa.

Declaração sobre uso de Inteligência Artificial

Durante a preparação deste trabalho, os autores utilizaram um modelo de linguagem de grande escala (ChatGPT, versão 5.2) como apoio à revisão textual, especificamente para correções ortográficas e gramaticais, bem como para verificar a clareza e a estrutura de alguns trechos. A concepção do estudo, o desenho metodológico, a análise e interpretação dos dados e a redação do conteúdo científico foram conduzidos integralmente pelos autores. A ferramenta foi empregada apenas na etapa final de revisão, sem contribuir para o conteúdo intelectual do estudo ou para as conclusões apresentadas. Todas as sugestões geradas foram avaliadas criticamente, sendo os autores integralmente responsáveis pela versão final do trabalho.

Referências

- Afroogh, S., Akbari, A., Malone, E., Kargar, M., and Alambeigi, H. (2024). Trust in ai: progress, challenges, and future directions. *Humanities and Social Sciences Communications*, 11(1):1–30.
- Ahmad, K., Abdelrazek, M., Arora, C., Baniya, A. A., Bano, M., and Grundy, J. (2023). Requirements engineering framework for human-centered artificial intelligence software systems. *Applied Soft Computing*, 143:110455.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., et al. (2020). Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible ai. *Information fusion*, 58:82–115.
- Bauer, C., Said, A., and Zangerle, E. (2024). Evaluation perspectives of recommender systems: Driving research and education (dagstuhl seminar 24211). *Dagstuhl Reports*, 14(5):58–172.

- Cooper, A. et al. (2004). *The inmates are running the asylum: Why high-tech products drive us crazy and how to restore the sanity*, volume 2. Sams Indianapolis.
- Duricic, T., Kowald, D., Lacic, E., and Lex, E. (2023). Beyond-accuracy: a review on diversity, serendipity, and fairness in recommender systems based on graph neural networks. *Frontiers in big data*, 6:1251072.
- Gheewala, S., Xu, S., and Yeom, S. (2025). In-depth survey: deep learning in recommender systems—exploring prediction and ranking models, datasets, feature analysis, and emerging trends. *Neural Computing and Applications*, 37(17):10875–10947.
- Gray, D., Brown, S., and Macanuso, J. (2010). *Gamestorming: A playbook for innovators, rulebreakers, and changemakers*. "O'Reilly Media, Inc."
- Jadon, A. and Patil, A. (2024). A comprehensive survey of evaluation techniques for recommendation systems. In *International Conference on Computation of Artificial Intelligence & Machine Learning*, pages 281–304. Springer.
- Liao, Q. V., Gruen, D., and Miller, S. (2020). Questioning the ai: informing design practices for explainable ai user experiences. In *Proceedings of the 2020 CHI conference on human factors in computing systems*, pages 1–15.
- Minh, D., Wang, H. X., Li, Y. F., and Nguyen, T. N. (2022). Explainable artificial intelligence: a comprehensive review. *Artificial Intelligence Review*, 55(5):3503–3568.
- Mohamed, A., Abdelqader, K., and Shaalan, K. (2025). Explainable artificial intelligence: A systematic review of progress and challenges. *Intelligent Systems with Applications*, page 200595.
- Raza, S., Rahman, M., Kamawal, S., Toroghi, A., Raval, A., Navah, F., and Kazemeini, A. (2024). A comprehensive review of recommender systems: Transitioning from theory to practice. *arXiv preprint arXiv:2407.13699*.
- Ricci, F., Rokach, L., and Shapira, B. (2021). Recommender systems: Techniques, applications, and challenges. *Recommender systems handbook*, pages 1–35.
- Santos, B., Lima, M., Ribeiro, M., and Conte, T. (2025). Teaching requirements engineering for human-centered ai: A classroom experience with the re4hcai framework. In *Simpósio Brasileiro de Qualidade de Software (SBQS)*, pages 540–550. SBC.
- Shneiderman, B. (2020). Human-centered artificial intelligence: Reliable, safe & trustworthy. *International Journal of Human–Computer Interaction*, 36(6):495–504.
- Vilone, G. and Longo, L. (2020). Explainable artificial intelligence: a systematic review. *arXiv preprint arXiv:2006.00093*.
- Vistorte, A. O. R., Deroncele-Acosta, A., Ayala, J. L. M., Barrasa, A., López-Granero, C., and Martí-González, M. (2024). Integrating artificial intelligence to assess emotions in learning environments: a systematic literature review. *Frontiers in psychology*, 15:1387089.
- Zhang, K., Xie, Y., He, Y., and Wang, J. (2025). Emotional influences on user continuous use intention in recommended news apps: A study of algorithm appreciation and fatigue within the cognition-affect-conation framework. *Acta Psychologica*, 256:105002.