

Letramento em *Feedback* e Inteligência Artificial Explicável no Ensino Superior de Computação: um Mapeamento Sistemático

Victor A. dos Santos Ferreira^{1,2}, Patrícia Cabral De Azevedo Restelli Tedesco¹,
Hemilis Joyse Barbosa Rocha^{3,4}

¹Centro de Informática – Universidade Federal de Pernambuco (UFPE)
Recife, PE – Brasil

²Universidade de Pernambuco, *Campus Garanhuns* (UPE)
CEP 55.294-902 – Garanhuns – PE - Brasil

³Programa de Pós-Graduação em Informática (PPGI), Instituto de Computação,
Universidade Federal de Alagoas (UFAL), Maceió, AL, Brasil

⁴Instituto Federal de Alagoas (IFAL), Campus Viçosa, Viçosa, AL, Brasil

{vasf, pcart}@cin.ufpe.br, hemilis.rocha@ifal.edu.br

Abstract. *Automated systems and LLMs have expanded personalized feedback in Computing-related higher education, but raise issues of reliability, explainability, and critical use. This systematic mapping examines the articulation among feedback literacy, automated feedback, and XAI. From 586 retrieved records, 18 articles were selected for extraction and analysis. Results show partial articulation, with predominance of Learning Analytics, adaptive approaches, and LLM-based clarification, while formal XAI remains limited. Gaps concern criteria, evidence, recommendation limits, next steps, and student heterogeneity.*

Resumo. *Sistemas automatizados e LLMs ampliaram o feedback personalizado em contextos relacionados ao ensino superior de Computação, mas trazem desafios de confiabilidade, explicabilidade e uso crítico. Este mapeamento sistemático examina a articulação entre letramento em feedback, feedback automatizado e XAI. A partir de 586 registros recuperados, 18 artigos foram selecionados para extração e análise. Os resultados indicam articulação parcial, com predomínio de Learning Analytics, abordagens adaptativas e clarificação baseada em LLM, enquanto a XAI formal permanece restrita. As lacunas envolvem critérios, evidências, limites das recomendações, próximos passos e heterogeneidade discente.*

1. Introdução

A formação em Computação no ensino superior tem sido orientada pelo desenvolvimento de competências, pela produção de artefatos e pela demonstração de evidências de desempenho. Diretrizes curriculares e parâmetros de qualificação profissional deslocam o foco da transmissão de conteúdos para a capacidade de analisar problemas, projetar soluções computacionais e justificar decisões em situações próximas da prática profissional [ABET 2023; Kumar et al. 2024]. Nesse contexto, a avaliação da

aprendizagem envolve ciclos de produção, *feedback*, revisão e aprimoramento do desempenho.

O *feedback* ocupa papel central nesses ciclos, pois relaciona o desempenho atual do estudante a critérios de qualidade e metas de aprendizagem [Sadler 1989; Nicol and Macfarlane-Dick 2006; Hattie and Timperley 2007]. Em disciplinas de Computação, especialmente em tarefas de programação, submissões sucessivas, testes, depuração e reenvio de soluções intensificam essa dinâmica. Sistemas de avaliação automatizada contribuem para lidar com a escala e a frequência das devolutivas, embora muitas ferramentas ainda privilegiem a identificação de erros, com menor ênfase na explicitação de critérios, estratégias de correção e raciocínios subjacentes [Douce, Livingstone and Orwell 2005; Keuning et al. 2018; Messer et al. 2024].

A incorporação de sistemas baseados em Inteligência Artificial e *Large Language Models* (LLMs) amplia as possibilidades de geração de *feedback* em linguagem natural [Kasneci et al. 2023]. Entretanto, a fluidez textual das respostas não assegura confiabilidade, pertinência pedagógica ou transparência, pois esses modelos podem apresentar vieses, opacidade, inconsistências e informações apenas aparentemente plausíveis [Bender et al. 2021; Bommasani et al. 2021; Ji et al. 2023]. Nesse cenário, a Inteligência Artificial Explicável (*Explainable Artificial Intelligence - XAI*) torna-se relevante para discutir como sistemas automatizados podem tornar mais compreensíveis suas saídas, critérios e limites [Arrieta et al. 2020; Khosravi et al. 2022].

A explicação de uma devolutiva, contudo, não garante que o estudante consiga interpretá-la ou utilizá-la de forma produtiva. O letramento em *feedback* desloca o foco da produção da mensagem para sua apropriação pelo estudante, compreendida como capacidade de interpretar, avaliar e utilizar *feedback* para aprimorar o próprio trabalho [Carless and Boud 2018; Winstone et al. 2017]. Diante disso, este trabalho apresenta um mapeamento sistemático da literatura com o objetivo de caracterizar como letramento em *feedback*, *feedback* automatizado e XAI têm sido articulados em estudos relacionados ao ensino superior de Computação. A principal contribuição consiste em analisar conjuntamente as dimensões técnica e pedagógica do *feedback* automatizado, relacionando as formas de explicabilidade identificadas às condições que favorecem a compreensão, a avaliação e o uso das devolutivas pelos estudantes. A análise contempla tipos de explicação, heterogeneidade discente, metodologias pedagógicas, evidências de impacto, barreiras de implementação e diretrizes de *design*.

2. Fundamentação Teórica

A avaliação formativa compreende o *feedback* como parte de um processo de regulação da aprendizagem, no qual critérios, evidências e decisões orientam a melhoria do desempenho. Nessa perspectiva, o *feedback* não se reduz à comunicação de erros ou acertos, pois apoia o estudante na comparação entre o que produziu e os padrões de qualidade esperados [Sadler 1989; Black and Wiliam 2010]. Esse processo também se articula à autorregulação, uma vez que o estudante precisa monitorar o próprio desempenho, interpretar informações externas e decidir como ajustar suas estratégias de aprendizagem [Nicol and Macfarlane-Dick 2006].

A entrega de uma devolutiva não garante sua apropriação pelo estudante, pois o *feedback* externo interage com processos internos de monitoramento, julgamento e

tomada de decisão [Butler and Winne 1995; Hattie and Timperley 2007]. Essa discussão se aproxima do letramento em *feedback*, compreendido como a capacidade de compreender, avaliar e utilizar *feedback* para aprimorar o próprio trabalho [Carless and Boud 2018]. Barreiras podem ocorrer quando os critérios são pouco claros ou quando não existem oportunidades efetivas de revisão [Winstone et al. 2017].

Nesse contexto, *Learning Analytics* refere-se à coleta, à análise e à interpretação de dados sobre os estudantes e seus contextos, com a finalidade de compreender e apoiar os processos de aprendizagem [Siemens 2013]. No âmbito do *feedback* automatizado, essas análises podem contribuir para a identificação de padrões de desempenho e interação, o acompanhamento do progresso e a personalização das devolutivas.

Em disciplinas de Computação, os estudantes produzem artefatos executáveis, testam soluções, corrigem erros e reenviam versões ao longo da tarefa, o que favorece o uso de sistemas de avaliação automatizada em contextos de grande escala [Douce, Livingstone and Orwell 2005]. A incorporação de LLMs amplia esse cenário ao permitir explicações e sugestões em linguagem natural, mas não elimina problemas de confiabilidade, consistência e alinhamento aos critérios pedagógicos [Bender et al. 2021; Bommasani et al. 2021; Ji et al. 2023; Kasneci et al. 2023].

A XAI reúne abordagens voltadas a tornar sistemas de Inteligência Artificial e seus resultados mais compreensíveis para usuários humanos [Arrieta et al. 2020]. Em contextos educacionais, essa compreensão precisa considerar tanto os aspectos técnicos quanto as necessidades dos sujeitos envolvidos no processo de aprendizagem [Khosravi et al. 2022]. Neste trabalho, *feedback* automatizado, XAI e letramento em *feedback* são tratados como dimensões distintas e complementares: o primeiro corresponde à produção ou entrega de devolutivas com apoio computacional; a segunda pode tornar mais compreensíveis as evidências, os critérios, o funcionamento e os limites associados às devolutivas; e o terceiro se refere à capacidade do estudante de interpretá-las, avaliá-las e utilizá-las. Essa relação não se estabelece automaticamente, pois uma devolutiva pode ser automatizada sem oferecer elementos suficientes de explicação, enquanto uma explicação tecnicamente compreensível pode não favorecer sua apropriação pedagógica [Khosravi et al. 2022; Carless and Boud 2018]. A explicabilidade pode apoiar o letramento em *feedback* ao favorecer o julgamento da pertinência da devolutiva e a definição de ações de revisão, embora esse processo também dependa de mediação pedagógica e de oportunidades efetivas de uso [Carless and Boud 2018; Winstone et al. 2017].

3. Protocolo do Mapeamento Sistemático

Este estudo foi conduzido como um mapeamento sistemático da literatura, com o objetivo de identificar, caracterizar e analisar como a produção científica tem articulado Letramento em Feedback (*Feedback Literacy*), *feedback* automatizado e Inteligência Artificial Explicável em contextos relacionados ao ensino superior de Computação. A organização metodológica tomou como referência diretrizes para revisões e mapeamentos sistemáticos da literatura [Kitchenham and Charters 2007; Kitchenham, Budgen and Brereton 2016]. O processo foi estruturado em três etapas complementares: planejamento, condução e síntese dos resultados, abrangendo desde a definição das

questões de pesquisa e dos critérios de seleção até a triagem, extração, categorização e análise dos estudos, conforme detalhado nas subseções seguintes.

3.1. Questões de pesquisa

Com base no objetivo deste trabalho, formulou-se uma questão norteadora (QN), que delimita o problema central investigado pelo mapeamento, e seis questões de pesquisa auxiliares (QP1 a QP6), destinadas a orientar a extração, a categorização e a síntese dos estudos selecionados. A QN e as questões auxiliares são apresentadas no Quadro 1.

Quadro 1. Questões de pesquisa.

Código	Questão de pesquisa
QN	Quais abordagens integram Letramento em <i>Feedback</i> e Inteligência Artificial Explicável no ensino superior de Computação?
QP1	Quais tipos de explicações XAI são usados para fornecer <i>feedback</i> no ensino de Computação?
QP2	Como perfis cognitivos ou a heterogeneidade dos estudantes são considerados na interpretação do <i>feedback</i> automatizado?
QP3	Quais metodologias pedagógicas estão associadas ao uso de <i>feedback</i> automatizado baseado em XAI?
QP4	Quais evidências de impacto na aprendizagem são reportadas para <i>feedback</i> automatizado com XAI?
QP5	Quais barreiras ou desafios na implementação de <i>feedback</i> automatizado com XAI são relatados?
QP6	Quais diretrizes ou boas práticas são recomendadas para o <i>design</i> explicável de <i>feedback</i> automatizado no contexto educacional?

3.2. Fontes de busca e estratégia de busca

A busca foi realizada nas bases *ACM Digital Library*, *Scopus*, *IEEE Xplore*, *Google Scholar*, *ScienceDirect*, *Springer* e *ERIC*, selecionadas por abrangerem publicações em Computação, Educação, tecnologia educacional e inteligência artificial. Não foi aplicado recorte temporal de publicação. A estratégia de busca adotou como eixo obrigatório o termo “*feedback literacy*”, combinado a expressões relacionadas a *feedback* automatizado e Inteligência Artificial Explicável, conforme a *string* matriz: “*feedback literacy*” AND (“*automated feedback*” OR “*explainable artificial intelligence*” OR “*explainable AI*” OR “*XAI*”). A *string* foi adaptada à sintaxe de cada base, preservando os eixos conceituais definidos no protocolo.

3.3. Estratégia de seleção dos estudos

A seleção dos estudos considerou publicações em inglês ou português, desde que recuperadas pela estratégia de busca definida e aderentes ao escopo do mapeamento. Embora a *string* tenha sido formulada em inglês, essa escolha decorreu da predominância internacional dos termos *feedback literacy*, *automated feedback* e *Explainable Artificial Intelligence* nas bases consultadas. Assim, publicações em

português não foram excluídas pelo critério linguístico, ainda que a estratégia de recuperação tenha permanecido orientada por descritores em inglês.

Os critérios de seleção foram definidos a partir da aderência dos estudos aos constructos centrais da pesquisa: letramento em *feedback*, *feedback* automatizado, *Learning Analytics*, sistemas adaptativos, XAI e ensino superior de Computação. A seleção não se restringiu aos estudos que mencionavam simultaneamente *feedback literacy* e XAI, pois essa exigência poderia excluir publicações relevantes sobre *feedback* automatizado, *Learning Analytics* ou explicabilidade em contextos educacionais relacionados ao recorte do estudo. Os critérios operacionais de inclusão e exclusão são sistematizados no Quadro 2.

Quadro 2. Critérios de inclusão e exclusão.

Código	Critério
CI1	Publicações em periódicos, conferências ou eventos científicos.
CI2	Estudos escritos em inglês ou português, desde que recuperados pela estratégia de busca definida.
CI3	Estudos relacionados a <i>Feedback Literacy</i> , <i>feedback</i> automatizado, <i>Learning Analytics</i> , sistemas adaptativos, XAI ou tecnologias correlatas.
CI4	Estudos com aderência ao ensino superior de Computação ou a contextos de ensino superior com componente computacional explícito.
CE1	Trabalhos duplicados.
CE2	Estudos secundários ou terciários
CE3	Capítulos, editoriais, textos introdutórios de anais, chamadas, prefácios, bibliografias comentadas ou publicações sem estudo primário identificável.
CE4	Publicações sem texto completo disponível.
CE5	Estudos fora do escopo temático da pesquisa.

A triagem dos estudos foi organizada em etapas sucessivas, nas quais dois avaliadores independentes examinaram os títulos e os resumos dos registros recuperados, considerando sua aderência ao escopo do mapeamento. Em uma segunda etapa, os estudos mantidos após a triagem inicial foram reavaliados com base na leitura da introdução e da conclusão. Na terceira etapa, os textos completos dos estudos remanescentes foram examinados mediante a aplicação definitiva dos critérios de inclusão e exclusão.

Os casos de dúvida ou divergência foram encaminhados a um terceiro avaliador, que reaplicou os critérios do protocolo para decidir o avanço dos registros e, na leitura integral, sua inclusão final. Foram registradas 94 ocorrências de arbitragem, envolvendo 81 registros únicos: 70 na triagem por títulos e resumos, 11 na leitura da introdução e da conclusão e 13 na leitura integral. Na primeira etapa, 58 casos decorreram de divergência, dez de dúvida de um avaliador e dois de dúvida de ambos. Os motivos, relacionados sobretudo à aderência aos constructos e ao ensino superior de Computação,

ao tipo de estudo e à insuficiência de informações nas etapas iniciais, estão detalhados na planilha de controle do repositório anonimizado.

3.4. Extração e análise dos dados

Os dados dos estudos incluídos foram extraídos em planilha estruturada, organizada a partir das questões de pesquisa do mapeamento. Os campos contemplaram informações bibliográficas e contextuais, como identificador, fonte, título, ano, autores e local de publicação, além de informações relacionadas ao objeto investigado, incluindo tipo de estudo, tipo de *feedback*, técnica, mecanismo ou recurso de explicabilidade, metodologia pedagógica associada, métricas ou formas de avaliação, respostas às questões de pesquisa, trabalhos futuros e lacunas indicadas pelos autores.

A análise dos dados combinou síntese narrativa, categorização analítica e estatística descritiva simples. A síntese narrativa foi utilizada para interpretar como os estudos articulam letramento em *feedback*, *feedback* automatizado e XAI. A categorização analítica permitiu distinguir diferentes níveis de aderência ao recorte investigado. A estatística descritiva, por sua vez, foi empregada de forma complementar, restrita à apresentação de frequências e distribuições dos campos extraídos, sem aplicação de testes inferenciais.

Para fins de síntese quantitativa, as QPs 1 a 4 foram organizadas em categorias mutuamente excludentes, atribuindo-se a cada estudo a categoria que melhor representava o aspecto predominante identificado na extração. Para as QPs 5 e 6, adotou-se categorização não excludente, uma vez que um mesmo artigo poderia relatar mais de uma barreira ou recomendar mais de uma diretriz de *design*, razão pela qual os resultados foram contabilizados como menções temáticas.

Os dados de busca, triagem, extração e categorização utilizados neste mapeamento foram organizados em planilhas e disponibilizados em repositório anonimizado: <https://github.com/vasf22/dataset-RLS>.

3.5. Ameaças à validade

A cobertura deste mapeamento pode ter sido limitada pela formulação da *string* em inglês e pelas bases consultadas, embora estudos em inglês ou português fossem elegíveis. A seleção e a categorização também envolveram decisões interpretativas, mitigadas pela avaliação independente de dois revisores, pela participação de um terceiro nos casos de dúvida ou divergência e pelo registro das decisões. Como não foi realizada avaliação formal da qualidade metodológica, os resultados caracterizam tendências e lacunas da literatura, sem constituir evidência conclusiva sobre a eficácia das intervenções.

4. Resultados e Discussão

A análise dos resultados inicia-se pela descrição do processo de busca e seleção dos estudos, etapa necessária para explicitar como os artigos selecionados para análise foram definidos. Em seguida, os achados do mapeamento são discutidos a partir das questões de pesquisa, considerando as relações identificadas entre letramento em

feedback, *feedback* automatizado e Inteligência Artificial Explicável em contextos relacionados ao ensino superior de Computação.

4.1. Processo de seleção dos estudos

As buscas realizadas nas bases selecionadas retornaram 586 registros, distribuídos entre *Springer* (n = 480), *ScienceDirect* (n = 42), *Google Scholar* (n = 37), *ACM Digital Library* (n = 13), *IEEE Xplore* (n = 8), *Scopus* (n = 4) e *ERIC* (n = 2). Após a consolidação dos resultados, foi realizada a conferência de duplicidades por título, ano, base e link ou DOI disponível. Nessa etapa, foram identificados oito grupos de duplicidade provável ou confirmada, envolvendo 19 registros. Desse conjunto, 11 registros foram considerados redundantes e removidos, resultando em 575 registros únicos para a primeira etapa de seleção.

A aplicação inicial dos critérios de inclusão e exclusão considerou os títulos e os resumos dos registros recuperados. Essa etapa levou à rejeição de 439 registros que não atendiam ao recorte da pesquisa, sobretudo por não abordarem contextos relacionados ao ensino superior de Computação, letramento em *feedback*, *feedback* automatizado, *Learning Analytics* ou elementos de Inteligência Artificial Explicável de forma compatível com os objetivos do mapeamento. Ao final dessa triagem, 136 estudos foram mantidos para análise subsequente.

Na etapa seguinte, os 136 estudos foram reavaliados quanto à aderência ao escopo da pesquisa com base na leitura da introdução e da conclusão. Desse conjunto, 51 estudos não prosseguiram e 85 foram mantidos para avaliação integral. Por fim, os textos completos desses 85 estudos foram examinados mediante nova aplicação dos critérios de inclusão e exclusão. Após a resolução dos casos de dúvida ou divergência entre os avaliadores, 67 estudos foram excluídos e 18 artigos foram encaminhados para extração e análise dos dados.

A Figura 1 sintetiza o fluxo de seleção dos estudos, desde a recuperação inicial dos registros até a definição dos artigos encaminhados para extração.




Figura 1. Fluxo de seleção dos estudos.

4.2. Caracterização dos estudos selecionados

Os 18 artigos encaminhados para extração foram caracterizados segundo base de origem, ano de publicação e tipo de estudo. Embora a busca inicial tenha envolvido sete bases, os estudos selecionados concentraram-se em quatro fontes: *Springer*, com nove artigos, *ScienceDirect*, com quatro, *ACM Digital Library*, com três, e *Google Scholar*,

com dois. Nenhum artigo proveniente da *Scopus*, *IEEE Xplore* ou *ERIC* compôs o conjunto final de extração.

Quanto ao ano de publicação, observa-se concentração de estudos recentes, com maior presença de publicações em 2024 e 2025. Essa distribuição, apresentada na Figura 2, sugere que a articulação entre letramento em *feedback*, *feedback* automatizado e Inteligência Artificial Explicável ganhou maior visibilidade na literatura recente.




Figura 2. Distribuição dos artigos selecionados por ano de publicação.

Em relação ao tipo de estudo, predominam investigações experimentais ou quase-experimentais, seguidas por estudos de caso, *design* ou validação, estudos quantitativos ou metodológicos, pesquisas mistas e estudos qualitativos ou de *design* qualitativo. A Figura 3 apresenta essa distribuição e indica um campo recente, metodologicamente diverso e ainda em consolidação.




Figura 3. Distribuição dos artigos selecionados por tipo de estudo.

De modo geral, a caracterização dos estudos selecionados indica um campo recente, metodologicamente diverso e ainda em consolidação. A concentração temporal nos anos de 2024 e 2025 sugere intensificação do interesse pelo tema, enquanto a variedade de desenhos metodológicos mostra que a literatura ainda explora diferentes formas de investigar o uso de *feedback* automatizado e explicabilidade em contextos de ensino superior de Computação.

4.3. Análise dos estudos por questão de pesquisa

Com base nas questões de pesquisa definidas na seção 3.1 e nos procedimentos de extração e categorização descritos na seção 3.4, os 18 artigos selecionados foram analisados por categorias. Nas QPs 1 a 4, os resultados são apresentados por número e

percentual de estudos, pois cada artigo foi associado à categoria que melhor representava o aspecto predominante identificado na extração. Nas QPs 5 e 6, os resultados são apresentados como menções temáticas, uma vez que um mesmo artigo poderia relatar mais de uma barreira ou recomendar mais de uma diretriz de *design*.

QP1 – Quais tipos de explicações XAI são usados para fornecer feedback no ensino de Computação?

Os estudos foram classificados segundo o tipo de explicação associado ao *feedback* automatizado, distinguindo XAI formal, explicabilidade funcional ou indireta, clarificação textual baseada em LLM/GenAI, ausência de técnica XAI declarada e outras formas de explicação ou literacia em IA. As categorias mais recorrentes foram explicabilidade funcional ou indireta, identificada em cinco estudos (27,8%: EP02, EP35, EP160, EP370, EP579), clarificação textual baseada em LLM/GenAI, também em cinco estudos (27,8%: EP03, EP162, EP196, EP518, EP538), e ausência de técnica XAI declarada, igualmente em cinco estudos (27,8%: EP44, EP309, EP556, EP562, EP568). Apenas dois estudos declararam técnicas formais de XAI, equivalentes a 11,1% (EP04, EP48), e um estudo foi classificado em outras formas de explicação ou literacia em IA, correspondente a 5,6% (EP34). Assim, a resposta à QP1 indica que a explicabilidade aplicada ao *feedback* aparece principalmente como recurso funcional, textual ou pedagógico, enquanto a adoção de XAI formal permanece restrita.

QP2 – Como perfis cognitivos ou a heterogeneidade dos estudantes são considerados na interpretação do feedback automatizado?

A análise da QP2 considerou como os estudos tratam diferenças entre estudantes no processo de interpretação, personalização ou uso do *feedback* automatizado. Dez artigos consideraram a heterogeneidade por meio de atributos, perfis, interações ou variáveis dos estudantes, correspondendo a 55,6% do conjunto analisado (EP02, EP34, EP35, EP44, EP48, EP160, EP162, EP196, EP309, EP370). Outros sete estudos trataram a heterogeneidade de forma indireta ou contextual, representando 38,9% (EP03, EP04, EP518, EP538, EP562, EP568, EP579), enquanto apenas um, equivalente a 5,6%, não apresentou consideração explícita sobre diferenças entre estudantes (EP556). Esses dados sugerem que a heterogeneidade discente aparece principalmente como variável para personalização, adaptação ou interpretação de comportamentos, ainda pouco articulada ao desenvolvimento do letramento em *feedback*.

QP3 – Quais metodologias pedagógicas estão associadas ao uso de feedback automatizado baseado em XAI?

As metodologias e abordagens pedagógicas foram analisadas considerando sua função na mediação do *feedback*, no uso da explicação pelo estudante e no apoio à aprendizagem. Predominaram abordagens baseadas em *Learning Analytics*, *Feedback Analytics* ou *feedback* centrado no estudante, identificadas em seis estudos, correspondendo a 33,3% dos artigos analisados (EP02, EP04, EP35, EP518, EP538, EP556), e intervenções com IA/LLM, tutoria ou *prompting*, também presentes em seis estudos, equivalentes a 33,3% (EP03, EP162, EP196, EP309, EP562, EP568). Também foram observadas propostas de ensino adaptativo, personalização orientada por dados ou preparação para uso educacional de IA, presentes em cinco estudos, equivalentes a 27,8% (EP34, EP44, EP48, EP160, EP370), enquanto *peer feedback* ou autorregulação

com assistência de IA apareceu em apenas um estudo, correspondente a 5,6% (EP579). Esses resultados indicam que as metodologias associadas ao *feedback* automatizado com explicabilidade priorizam análise de dados educacionais, mediação por IA e personalização adaptativa, mas ainda pouco estruturam práticas voltadas à compreensão de critérios, avaliação da devolutiva e revisão do desempenho pelo estudante.

QP4 – Quais evidências de impacto na aprendizagem são reportadas para feedback automatizado com XAI?

Os estudos reportaram diferentes tipos de evidência para avaliar os efeitos do *feedback* automatizado, da explicabilidade ou dos recursos de IA no processo de aprendizagem. Sete artigos basearam seus achados em percepção, engajamento, satisfação ou usabilidade dos estudantes, correspondendo a 38,9% do conjunto analisado (EP02, EP03, EP35, EP44, EP196, EP518, EP538). Outros seis apresentaram medidas de desempenho, aprendizagem ou ação observável na tarefa, equivalentes a 33,3% (EP04, EP160, EP162, EP309, EP370, EP579), enquanto quatro avaliaram a qualidade do *feedback*, do modelo ou da ferramenta, correspondendo a 22,2% (EP48, EP556, EP562, EP568). Apenas um estudo, equivalente a 5,6%, apresentou evidência indireta relacionada à intervenção (EP34). A maior ocorrência de estudos centrados em percepção, engajamento, satisfação ou usabilidade sugere que parte da literatura ainda toma a recepção da tecnologia como evidência relevante de impacto, embora as evidências mais próximas da aprendizagem estejam nos estudos que mensuram desempenho, revisão, ação observável ou resultados educacionais.

QP5 – Quais barreiras ou desafios na implementação de feedback automatizado com XAI são relatados?

Os desafios identificados concentram-se em aspectos técnicos, pedagógicos e institucionais do uso de *feedback* automatizado com explicabilidade. Como as categorias são não excludentes, os resultados foram contabilizados como menções temáticas. As ocorrências mais frequentes envolveram limitações técnicas, confiabilidade, precisão ou interpretabilidade, com 12 menções (EP03, EP35, EP44, EP48, EP160, EP196, EP309, EP370, EP556, EP562, EP568, EP579), e aceitação, confiança, resistência ou uso crítico da IA, também com 12 menções (EP02, EP03, EP34, EP35, EP44, EP48, EP160, EP162, EP196, EP518, EP538, EP579). Barreiras relacionadas à escala, à qualidade do *feedback* ou à contextualização das devolutivas apareceram em sete menções (EP02, EP370, EP518, EP538, EP556, EP562, EP568), enquanto questões de privacidade, ética, governança ou vieses foram identificadas em cinco menções (EP160, EP518, EP556, EP568, EP579). A resposta à QP5 indica que os desafios têm natureza sociotécnica e pedagógica, pois envolvem tanto a qualidade dos modelos e das explicações quanto as condições de uso, interpretação e validação das devolutivas em contextos educacionais.

QP6 – Quais diretrizes ou boas práticas são recomendadas para o design explicável de feedback automatizado no contexto educacional?

Quanto às diretrizes de *design*, os estudos analisados apontam recomendações relacionadas à transparência, ao *feedback* acionável, à personalização, à mediação humana e ao uso responsável da IA. Transparência, explicitação de limites ou compreensão crítica das saídas da IA apareceram em sete menções (EP04, EP35, EP48, EP160, EP196, EP370, EP538). *Feedback* acionável também apareceu em sete menções

(EP04, EP35, EP518, EP538, EP556, EP562, EP568), assim como personalização (EP02, EP34, EP35, EP44, EP48, EP162, EP309). A mediação humana foi identificada em cinco menções (EP02, EP03, EP562, EP568, EP579), enquanto ética, privacidade, governança e integração responsável apareceram em quatro (EP160, EP518, EP556, EP568). Esses achados indicam que o *design* explicável de *feedback* automatizado precisa articular clareza sobre funcionamento e limites da IA, devolutivas orientadas à ação, adaptação ao contexto do estudante e condições responsáveis de uso. Nesse sentido, a explicabilidade assume função pedagógica quando explicita critérios, evidências, limites da recomendação e próximos passos possíveis, favorecendo a compreensão do *feedback* e seu uso na revisão do desempenho.

O Quadro 3 consolida as respostas às questões de pesquisa, destacando a síntese dos achados e a implicação analítica associada a cada eixo investigado. Essa organização permite observar, de forma integrada, os principais padrões identificados no conjunto analisado.

Quadro 3. Síntese das respostas às questões de pesquisa.

QP	Síntese dos achados	Implicação analítica
QP1	Predominam explicações funcionais, textuais ou pedagógicas, com baixa presença de XAI formal.	Há lacuna entre explicar o <i>feedback</i> e explicitar critérios, evidências, incertezas e limites da recomendação automatizada.
QP2	A heterogeneidade discente aparece principalmente associada a atributos observáveis e variáveis de modelagem	Diferenças entre estudantes ainda são pouco tratadas como dimensão pedagógica do letramento em <i>feedback</i> .
QP3	As metodologias concentram-se em <i>Learning Analytics</i> , IA/LLM, tutoria, <i>prompting</i> e personalização adaptativa.	A explicação aparece mais como funcionalidade do sistema do que como parte de uma sequência pedagógica de uso crítico do <i>feedback</i> .
QP4	As evidências de impacto incluem percepção, engajamento, satisfação, desempenho, qualidade do <i>feedback</i> /modelo e evidência indireta.	Faltam estudos longitudinais que relacionem explicabilidade, melhoria entre versões e desenvolvimento do letramento em <i>feedback</i> .
QP5	As barreiras envolvem confiabilidade técnica, aceitação, uso crítico da IA, contextualização, privacidade e governança.	A implementação depende de condições sociotécnicas e pedagógicas, não apenas da qualidade técnica do modelo.
QP6	As diretrizes apontam para transparência, <i>feedback</i> acionável, personalização, mediação humana e uso responsável dos dados.	O <i>design</i> explicável deve apoiar a compreensão de critérios, evidências, limites e próximos passos para revisão do desempenho.

A comparação dos estudos evidencia duas orientações principais, uma vez que EP04 e EP48 empregam técnicas formais de XAI para interpretar modelos ou previsões, enquanto EP03, EP162, EP196, EP518 e EP538 privilegiam explicações textuais, clareza e personalização das devolutivas, revelando prioridades distintas entre a transparência do sistema e a utilidade pedagógica do *feedback*. Também se observam diferenças nas evidências utilizadas para avaliar as intervenções, pois predominam

medidas de percepção, confiança e usabilidade, ao passo que poucos estudos acompanham a revisão, o desempenho ou o uso efetivo das devolutivas, situação que pode estar relacionada ao caráter recente e heterogêneo do campo, ainda marcado por estudos piloto e avaliações de curto prazo. Desse modo, a principal lacuna não se restringe à baixa adoção de técnicas formais de XAI, mas envolve sobretudo a escassez de desenhos de pesquisa que articulem explicação, julgamento da devolutiva, ação revisional e aprendizagem.

5. Conclusão e Trabalhos Futuros

Este mapeamento sistematizou como letramento em *feedback*, *feedback* automatizado e Inteligência Artificial Explicável têm sido articulados no ensino superior de Computação, evidenciando que, embora os estudos analisados explorem o uso de IA, personalização e explicações associadas às devolutivas, a integração desses recursos ao letramento em *feedback* ainda é limitada. A explicabilidade aparece com maior frequência como recurso funcional, textual ou pedagógico, voltado a tornar o *feedback* mais compreensível ou acionável, enquanto a adoção de técnicas formais de XAI permanece restrita, o que indica que explicar uma devolutiva não equivale, necessariamente, a tornar transparentes os critérios, as evidências e os limites que sustentam a recomendação automatizada.

No que se refere à heterogeneidade discente, os estudos privilegiam atributos observáveis, como desempenho, autorregulação, confiança e padrões de interação, favorecendo a personalização computacional, mas oferecendo ainda pouca compreensão sobre os modos pelos quais diferentes estudantes interpretam, julgam e utilizam o *feedback* recebido. As metodologias identificadas, especialmente *Learning Analytics*, IA, LLMs, tutoria, *prompting* e personalização adaptativa, apoiam a produção e a apresentação das devolutivas, mas ainda estruturam de forma limitada o trabalho pedagógico necessário para que o estudante compreenda os critérios, avalie a pertinência das explicações e utilize o *feedback* na revisão de seu desempenho.

Os achados indicam, portanto, que o avanço do *feedback* automatizado explicável depende menos da simples geração de explicações e mais da integração entre explicabilidade técnica, mediação pedagógica e letramento em *feedback*, de modo que as devolutivas não sejam apenas apresentadas, mas interpretadas, avaliadas e transformadas em ações de revisão. Nesse sentido, a principal lacuna não se restringe à baixa adoção de técnicas formais de XAI, mas envolve a escassez de abordagens que articulem, de forma contínua, explicação, julgamento da devolutiva, ação revisional e aprendizagem.

Como trabalhos futuros, recomenda-se o desenvolvimento de modelos de *feedback* automatizado que combinem explicabilidade técnica, mediação pedagógica e apoio explícito ao letramento em *feedback*, bem como a realização de estudos empíricos que acompanhem como os estudantes interpretam explicações automatizadas, utilizam as devolutivas em revisões sucessivas e desenvolvem maior autonomia no uso do *feedback*. Futuras pesquisas também podem explorar interfaces e protocolos pedagógicos que explicitem critérios, evidências, limites das recomendações e próximos passos para a revisão do desempenho.

Referências

- ABET (2023) Criteria for Accrediting Computing Programs, 2023–2024, ABET, Baltimore.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Benjamins, R., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, V. and Herrera, F. (2020) “Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI”, *Information Fusion*, v. 58, p. 82–115.
- Bender, E. M., Gebru, T., McMillan-Major, A. and Shmitchell, S. (2021) “On the dangers of stochastic parrots: Can language models be too big?”, In: *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT ’21)*, ACM, New York, p. 610–623.
- Black, P. and Wiliam, D. (2010) “Inside the black box: Raising standards through classroom assessment”, *Phi Delta Kappan*, v. 92, n. 1, p. 81–90.
- Bommasani, R., Hudson, D. A., Adluri, S., Altman, R., Arora, S., von Arx, S., Bernstein, M. S., Bohg, J., Bosselut, A., Brunskill, E. et al. (2021) “On the opportunities and risks of foundation models”, *Stanford Center for Research on Foundation Models*, Stanford.
- Butler, D. L. and Winne, P. H. (1995) “Feedback and self-regulated learning: A theoretical synthesis”, *Review of Educational Research*, v. 65, n. 3, p. 245–281.
- Carless, D. and Boud, D. (2018) “The development of student feedback literacy: Enabling uptake of feedback”, *Assessment & Evaluation in Higher Education*, v. 43, n. 8, p. 1315–1325.
- Douce, C., Livingstone, D. and Orwell, J. (2005) “Automatic test-based assessment of programming: A review”, *Journal on Educational Resources in Computing*, v. 5, n. 3, p. 1–13.
- Hattie, J. and Timperley, H. (2007) “The power of feedback”, *Review of Educational Research*, v. 77, n. 1, p. 81–112.
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y. J., Madotto, A. and Fung, P. (2023) “Survey of hallucination in natural language generation”, *ACM Computing Surveys*, v. 55, n. 12, article 248.
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, S. et al. (2023) “ChatGPT for good? On opportunities and challenges of large language models for education”, *Learning and Individual Differences*, v. 103, article 102274.
- Keuning, H., Jeuring, J. and Heeren, B. (2018) “A systematic literature review of automated feedback generation for programming exercises”, *ACM Transactions on Computing Education*, v. 19, n. 1, article 3.
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y. S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S. and Gašević, D. (2022) “Explainable Artificial Intelligence in education”, *Computers and Education: Artificial Intelligence*, v. 3, article 100074.

- Kitchenham, B. and Charters, S. (2007) Guidelines for Performing Systematic Literature Reviews in Software Engineering, Technical Report EBSE-2007-01, Keele University and Durham University Joint Report.
- Kitchenham, B., Budgen, D. and Brereton, P. (2016) Evidence-Based Software Engineering and Systematic Literature Reviews, CRC Press, Boca Raton.
- Kumar, A. N. et al. (2024) Computer Science Curricula 2023: Curriculum Guidelines for Undergraduate Degree Programs in Computer Science, Association for Computing Machinery, New York. DOI: 10.1145/3664191.
- Messer, M., Brown, N. C. C., Kölling, M. and Shi, M. (2024) “Automated grading and feedback tools for programming education: A systematic review”, ACM Transactions on Computing Education, v. 24, n. 1, article 10.
- Nicol, D. J. and Macfarlane-Dick, D. (2006) “Formative assessment and self-regulated learning: A model and seven principles of good feedback practice”, Studies in Higher Education, v. 31, n. 2, p. 199–218.
- Sadler, D. R. (1989) “Formative assessment and the design of instructional systems”, Instructional Science, v. 18, n. 2, p. 119–144.
- Siemens, G. (2013) “Learning analytics: The emergence of a discipline”, American Behavioral Scientist, v. 57, n. 10, p. 1380–1400.
- Winstone, N. E., Nash, R. A., Rowntree, J. and Parker, M. (2017) “‘It’d be useful, but I wouldn’t use it’: Barriers to university students’ feedback seeking and recipience”, Studies in Higher Education, v. 42, n. 11, p. 2026–2041.