

ARTIGO DE PESQUISA/RESEARCH PAPER

Qualiz: Gameificação para Ensinar e Engajar sobre a integração da Engenharia de Requisitos e Qualidade de Dados em Aprendizado de Máquina

Qualiz: Gamification to Teach and Engage on the Integration of Requirements Engineering and Data Quality in Machine Learning

Amanda Prampero Paes Mendes  [Universidade Estadual Paulista - UNESP | amanda.prampero@unesp.br]

Rogéria Cristiane Grato de Souza  [Universidade Estadual Paulista - UNESP | rogeria.souza@unesp.br]

 Instituto de Biociências, Letras e Ciências Exatas (IBILCE), Universidade Estadual Paulista (UNESP), Rua Cristóvão Colombo, 2265, Jardim Nazareth, São José do Rio Preto, SP, 15054-000, Brasil.

Resumo. A expansão de soluções baseadas em inteligência artificial tem intensificado a dependência de técnicas de aprendizado de máquina (*machine learning* – ML), o que torna a qualidade dos dados um fator determinante para o sucesso desses sistemas. A eficácia dos modelos depende diretamente de conjuntos de dados completos, consistentes e representativos, capazes de sustentar tanto a etapa de treinamento quanto a de validação. Entretanto, a literatura evidencia que problemas relacionados à baixa qualidade dos dados permanecem entre os principais responsáveis por falhas, vieses e degradação de desempenho em aplicações de ML. Nesse cenário, a engenharia de requisitos emerge como um campo estratégico, pois fornece métodos, processos e diretrizes que permitem identificar necessidades, estabelecer critérios de qualidade e antecipar riscos associados à coleta, preparação e manutenção dos dados utilizados nesses modelos. Apesar da relevância desse tema, observa-se uma lacuna significativa no que diz respeito a iniciativas educacionais direcionadas à capacitação sobre requisitos para qualidade de dados em ML, sobretudo em abordagens que conciliem aspectos técnicos e estratégias motivacionais. A literatura recente aponta a gameificação como um recurso promissor nesse contexto, dado seu potencial para tornar o processo de aprendizagem mais dinâmico, engajador e eficaz. Diante desse panorama, este artigo apresenta o Qualiz, um protótipo gameificado desenvolvido com o objetivo de disseminar boas práticas relacionadas à engenharia de requisitos aplicada à qualidade de dados em sistemas de ML. O protótipo foi disponibilizado a um grupo de 25 participantes, que interagiram livremente com a plataforma e posteriormente responderam a um formulário de avaliação. Os resultados revelaram uma avaliação predominantemente positiva: os participantes destacaram a boa compreensão dos tópicos apresentados, a relevância dos conceitos abordados e a adequação da estrutura dos *quizzes* para facilitar a assimilação gradual dos conteúdos. Além disso, a interface foi considerada intuitiva, e os elementos lúdicos foram vistos como fatores que aumentaram o interesse e a motivação durante o uso. A partir desses achados, identifica-se um potencial significativo do Qualiz como ferramenta complementar de apoio à formação em engenharia de requisitos voltada à qualidade de dados em ML, contribuindo tanto para o avanço da área quanto para a formação de profissionais mais preparados para atuar em cenários cada vez mais orientados por dados.

Abstract. The expansion of solutions based on artificial intelligence has intensified the reliance on machine learning (ML) techniques, making data quality a determining factor for the success of these systems. The effectiveness of models depends directly on complete, consistent, and representative datasets capable of supporting both the training and validation stages. However, the literature shows that issues related to poor data quality remain among the main causes of failures, biases, and performance degradation in ML applications. In this context, requirements engineering emerges as a strategic field, as it provides methods, processes, and guidelines that enable the identification of needs, the establishment of quality criteria, and the anticipation of risks associated with the collection, preparation, and maintenance of the data used in these models. Despite the relevance of this topic, there is a significant gap in educational initiatives aimed at training professionals on data quality requirements for ML, especially in approaches that reconcile technical aspects with motivational strategies. Recent literature highlights gamification as a promising resource in this context, given its potential to make the learning process more dynamic, engaging, and effective. Within this context, this article presents Qualiz, a gamified prototype developed with the aim of disseminating good practices related to requirements engineering applied to data quality in ML systems. The prototype was made available to a group of 25 participants, who freely interacted with the platform and subsequently completed an evaluation questionnaire. The results revealed a predominantly positive evaluation: participants highlighted their good understanding of the topics presented, the relevance of the concepts addressed, and the adequacy of the quiz structure in facilitating the gradual assimilation of content. In addition, the interface was considered intuitive, and the playful elements were perceived as factors that increased interest and motivation during use. Based on these findings, Qualiz demonstrates significant potential as a complementary tool to support training in requirements engineering focused on data quality in ML, contributing both to the advancement of the field and to the education of professionals better prepared to operate in increasingly data-driven environments.

Palavras-chave: Engenharia de requisitos, Qualidade de dados, Aprendizado de máquina

Keywords: Requirements engineering, Data quality, Machine learning

1 Introdução

Nos últimos anos, o crescimento exponencial de aplicações baseadas em inteligência artificial (IA) e aprendizado de máquina (ML) tem transformado setores como saúde, finanças, logística e educação. A eficácia e confiabilidade desses sistemas dependem diretamente da qualidade dos dados utilizados, pois é a partir deles que se assegura a integridade, a consistência e a representatividade dos modelos desenvolvidos [Nakajima and Nakatani, 2021]. Diferentemente do desenvolvimento de software tradicional, em que os requisitos tendem a ser bem definidos e estáveis, sistemas de ML demandam abordagens adaptativas e interdisciplinares, que integrem conceitos de engenharia de software, ciência de dados e IA [Pei *et al.*, 2022; Amershi *et al.*, 2019].

Nesse contexto, a engenharia de requisitos (ER) desempenha um papel estratégico, oferecendo métodos e diretrizes para identificar necessidades, definir critérios de qualidade e antecipar problemas relacionados aos dados, contribuindo para a construção de sistemas mais robustos e confiáveis [Vogelsang and Borg, 2019; Rangineni, 2023]. Apesar da relevância desse tema, observa-se uma lacuna significativa na formação de profissionais da área, principalmente no que diz respeito à identificação de critérios para assegurar a qualidade dos dados [Vogelsang and Borg, 2019; Amershi *et al.*, 2019].

Diante desse cenário, a gameificação surge como uma estratégia promissora para suprir essa lacuna, pois elementos lúdicos — *quizzes*, desafios interativos e recompensas — favorecem o engajamento e potencializam a retenção do conhecimento técnico [Seaborn and Fels, 2015; Teichner and Fortunato, 2015; Japiassu and Rached, 2020]. Nesse sentido, este trabalho apresenta o Qualiz, um protótipo gameificado que integra conteúdos de engenharia de requisitos e qualidade de dados em ML através de *quizzes* interativos. Assim, o principal objetivo é investigar de que maneira essa abordagem pode apoiar a compreensão dos conceitos envolvidos e contribuir para a formação de profissionais mais preparados para lidar com desafios relacionados aos dados.

2 Fundamentação Teórica

Nesta seção são apresentados os principais conceitos que sustentam o desenvolvimento do protótipo proposto, incluindo os fundamentos da engenharia de requisitos e sua aplicação em sistemas de aprendizado de máquina, a importância da qualidade de dados para o desempenho desses sistemas, e a utilização da gameificação como estratégia de aprendizado.

2.1 Engenharia de Requisitos: Conceitos e Aplicações em ML

A engenharia de requisitos é um conjunto estruturado de atividades voltadas à identificação, análise, validação e especificação das funcionalidades e restrições de um sistema. Tradicionalmente, os requisitos são classificados em funcionais, que descrevem os comportamentos e serviços esperados, e não funcionais, relacionados a qualidades como desempenho, segurança, confiabilidade e usabilidade [Pressman and Maxim, 2016; Sommerville, 2019]. A definição adequada desses requisitos é crucial para assegurar que o sistema atenda às expectativas dos stakeholders, reduzindo ambiguidades, inconsistências e retrabalho [Amershi *et al.*, 2019].

A relevância da ER se amplia quando aplicada a sistemas de aprendizado de máquina, cuja operação depende não apenas dos algoritmos implementados, mas da qualidade e representatividade dos dados utilizados em seu treinamento [Rangineni, 2023; Pei *et al.*, 2022]. Nesse contexto, o levantamento de requisitos desloca-se parcialmente para questões relacionadas à curadoria, validação e tratamento de dados, exigindo abordagens adaptativas e interdisciplinares que integrem conceitos de engenharia de software, ciência de dados e inteligência artificial [Vogelsang and Borg, 2019; Nakajima and Nakatani, 2021].

Além disso, requisitos não funcionais tradicionais passam a assumir novas dimensões em sistemas de ML. Aspectos como explicabilidade, que permite compreender decisões do modelo; robustez, relacionada à resistência a ruídos e variações nos dados; justiça algorítmica, visando reduzir vieses; e confiabilidade, ligada à operação consistente do sistema, tornam-se essenciais [Vogelsang and Borg, 2019]. A avaliação desses critérios frequentemente envolve métricas empíricas aplicadas a conjuntos de validação, como acurácia, precisão e *F1-score*, e requer prototipação iterativa e experimentação contínua, substituindo a especificação antecipada típica de projetos de software tradicionais [Vogelsang and Borg, 2019; Pei *et al.*, 2022].

Normas técnicas, como a ISO/IEC 25012, fornecem suporte à definição e avaliação da qualidade dos dados, oferecendo um modelo estruturado que distingue características inerentes (como precisão e completude) e dependentes de contexto (como atualidade, acessibilidade, interpretabilidade) [International Organization for Standardization, 2008; Nakajima and Nakatani, 2021]. Essa abordagem permite que os requisitos incorporem critérios de rastreabilidade, clareza, verificabilidade e viabilidade técnica, promovendo sistemas mais confiáveis e robustos [International Organization for Standardization, 2008].

Finalmente, os fluxos de trabalho em ML são intrinsecamente não lineares e dependentes de ciclos de *feedback*, nos quais etapas como treinamento, validação e implantação frequentemente exigem retornos a fases anteriores. Ademais, o fenômeno do *component entanglement*, caracterizado pela interdependência entre modelos, torna a modularização mais complexa e demanda acompanhamento constante da arquitetura do sistema. Dessa forma, a adoção de estratégias como monitoramento contínuo, *pipelines* automatizados e procedimentos sistemáticos de *retraining* reforça a necessidade de uma engenharia de requisitos adaptativa, capaz de lidar com a complexidade, a dinâmica dos dados e a evolução contínua dos sistemas [Amershi *et al.*, 2019].

2.2 Qualidade de Dados em Sistemas de ML

A qualidade dos dados constitui um dos pilares fundamentais para o desempenho, a confiabilidade e a robustez de sistemas baseados em aprendizado de máquina, uma vez que modelos preditivos dependem diretamente das propriedades estatísticas, semânticas e estruturais dos conjuntos de dados que os alimentam. Na literatura, esse conceito é abordado de forma multidimensional, contemplando atributos como completude, consistência, precisão, atualidade, unicidade e conformidade. Cada uma dessas dimensões desempenha um papel decisivo

no processo de modelagem: enquanto a completude assegura que todas as informações necessárias estejam presentes, a consistência evita contradições lógicas; a precisão garante que os dados reflitam adequadamente a realidade; a atualidade avalia se os registros são temporalmente relevantes; a unicidade elimina duplicidades; e a conformidade verifica a aderência a padrões e formatos previamente definidos [International Organization for Standardization, 2008]. A ausência de qualquer dessas propriedades pode comprometer a capacidade de generalização dos modelos, conduzindo a resultados distorcidos e, em contextos sensíveis, a implicações éticas, como a perpetuação de vieses discriminatórios [Rangineni, 2023].

Embora o modelo ISO/IEC 25012 tenha sido originalmente concebido para bases de dados convencionais, esforços recentes buscam adaptá-lo às particularidades de sistemas de IA. Entre essas iniciativas, destaca-se a extensão proposta por Nakajima and Nakatani [2021], que introduz dimensões adicionais voltadas a desafios contemporâneos, como adequação e proveniência. A adequação examina o alinhamento entre os dados e os objetivos específicos da tarefa de aprendizado, envolvendo critérios como relevância das variáveis, correção dos rótulos e representatividade das amostras. Já a proveniência trata da rastreabilidade das informações, incluindo sua origem, histórico de transformações e justificativas éticas para o uso. Ao incorporar essas dimensões, amplia-se a capacidade de verificar não apenas a qualidade intrínseca dos dados, mas também sua legitimidade e transparência, aspectos cruciais para sistemas que influenciam processos decisórios automatizados.

A literatura também evidencia que a qualidade dos dados deve ser tratada como uma responsabilidade contínua e compartilhada ao longo de todas as etapas do ciclo de desenvolvimento. Estudos como o de Amershi *et al.* [2019] mostram que problemas identificados nas fases posteriores, como inconsistências ou ruídos durante a validação dos modelos, frequentemente exigem o retorno às etapas de coleta ou pré-processamento — movimento típico de fluxos de trabalho iterativos em ML. De modo similar, Rangineni [2023] ressalta que falhas na gestão da qualidade ao longo do *pipeline* impactam diretamente a acurácia, a confiabilidade e a imparcialidade dos modelos, reforçando a necessidade de processos sistemáticos e contínuos para monitoramento e aprimoramento dos dados.

Nesse cenário, abordagens modernas como DataOps e MLOps têm ganhado destaque por oferecerem práticas, ferramentas e estruturas organizacionais que sustentam a qualidade dos dados em ambientes reais. O DataOps promove integração, automação e controle rigoroso dos fluxos de dados, favorecendo colaboração entre equipes e garantindo rastreabilidade em tempo real [Atwal, 2019]. O MLOps, por sua vez, aplica princípios de integração contínua, entrega contínua e treinamento contínuo ao ciclo de vida de sistemas de ML, automatizando processos como versionamento de modelos, auditoria de dados, detecção de *drift* e execução de rotinas de *retraining* [Kreuzberger *et al.*, 2023]. Ao articular esses mecanismos, estabelece-se uma infraestrutura mais confiável para garantir que dados e modelos permaneçam atualizados, estáveis e alinhados às expectativas dos usuários e das aplicações.

2.3 Gameificação como estratégia de aprendizado

No contexto educacional contemporâneo, especialmente em ambientes digitais e em programas de capacitação profissional, observa-se um crescimento expressivo da adoção de estratégias baseadas em elementos de jogos como forma de fomentar o engajamento e promover aprendizagens mais significativas. Em vez de depender de narrativas complexas, essa abordagem vale-se de mecânicas motivacionais — como progressão visível e reforços imediatos — para transformar conceitos abstratos em experiências práticas e interativas, favorecendo a participação ativa do aprendiz [Seaborn and Fels, 2015].

Estudos indicam que, quando bem estruturada, a utilização dessas mecânicas eleva a motivação intrínseca e melhora a retenção, especialmente em disciplinas que exigem raciocínio lógico e resolução de problemas [Ibáñez *et al.*, 2014; Japiassu and Rached, 2020]. Além disso, a adoção de atividades práticas — *quizzes*, simulações e desafios crescentes — aproxima teoria e prática e estimula tanto habilidades cognitivas quanto competências socioemocionais, como colaboração e autogestão.

Diversos elementos recorrentes são destacados na literatura [Teichner and Fortunato, 2015; Seaborn and Fels, 2015] como essenciais para a eficácia dessa estratégia, incluindo:

- Sistemas de pontuação, que evidenciam o desempenho e o progresso do participante;
- Níveis de progressão, que estabelecem metas graduais e reforçam a motivação por meio de marcos alcançáveis;
- *Feedback* imediato, que orienta ajustes rápidos e consolida o aprendizado por tentativa e erro;
- Desafios adaptativos, que ajustam a dificuldade conforme o avanço do usuário, promovendo equilíbrio entre desafio e habilidade.

No presente trabalho, essa estratégia é adotada como suporte pedagógico do protótipo Qualiz, cujo propósito é aproximar os conceitos de engenharia de requisitos e qualidade de dados à prática formativa. Ao converter conteúdos teóricos em atividades curtas e interativas, espera-se aumentar o engajamento dos usuários e facilitar a consolidação de conhecimentos relevantes para a atuação em projetos de ML.

3 Trabalhos Relacionados

Nesta seção são abordados alguns trabalhos que dialogam com a proposta desenvolvida, incluindo iniciativas educacionais voltadas ao ensino de aprendizado de máquina e ferramentas lúdicas aplicadas à engenharia de software. Dessa forma, as soluções analisadas adotam perspectivas semelhantes quanto à forma de ensino, sendo, contudo, complementares no que diz respeito ao conteúdo abordado.

O *Machine Learning Crash Course* (MLCC), desenvolvido pelo Google [2018], é uma iniciativa voltada à introdução ao aprendizado de máquina, oferecendo vídeos, exercícios e visualizações interativas como estratégias pedagógicas. Assim como o Qualiz, o MLCC utiliza recursos interativos para favorecer a aprendizagem ativa. No entanto, seu foco está na apresentação de conceitos fundamentais de aprendizado de máquina e em aspectos técnicos de modelagem, abordando a

qualidade de dados apenas de maneira complementar. Em contraste, o protótipo desenvolvido neste trabalho direciona-se especificamente à disseminação de boas práticas relacionadas à definição de requisitos voltados à qualidade de dados, sob a perspectiva da engenharia de requisitos aplicada a sistemas de ML, destacando-se por abordar de maneira central e estruturada um aspecto frequentemente tratado como secundário em iniciativas introdutórias.

No âmbito da engenharia de software, Lemos *et al.* [2020] desenvolveu o AD-RPG, ferramenta que utiliza dinâmicas de RPG para apoiar atividades de eliciação de requisitos. De forma semelhante, Liberato *et al.* [2024] propôs o Game-Test, que oferece desafios progressivos para exercitar práticas de testes de software. Ambas as propostas, assim como o Qualiz, adotam elementos de gameificação como estratégia de engajamento e consolidação do aprendizado. Entretanto, tais soluções concentram-se em domínios específicos da engenharia de software tradicional, mantendo-se no escopo clássico do desenvolvimento de sistemas. Nesse contexto, observa-se que os desafios associados à definição de requisitos voltados à qualidade dos dados em sistemas baseados em ML permanecem pouco explorados por abordagens lúdicas. Assim, ao direcionar-se explicitamente a esse recorte, o protótipo proposto busca preencher essa lacuna, ampliando o escopo das ferramentas educacionais gameificadas existentes.

À luz das iniciativas analisadas, observa-se que a adoção de estratégias lúdicas e interativas tem se consolidado como alternativa eficaz no ensino de competências técnicas. Todavia, permanece incipiente a aplicação dessa abordagem ao contexto específico da qualidade de dados sob a perspectiva da engenharia de requisitos em sistemas de aprendizado de máquina. Nesse cenário, a proposta apresentada insere-se como uma contribuição direcionada a esse segmento ainda pouco explorado, articulando fundamentos de engenharia de software e ciência de dados em uma solução educacional estruturada. Dessa forma, o trabalho não apenas dialoga com experiências já consolidadas, mas amplia seu escopo ao contemplar uma demanda emergente na formação de profissionais da área.

4 Metodologia

Para alcançar os objetivos deste trabalho, adotou-se uma abordagem metodológica estruturada em etapas complementares que abarcam desde a definição dos conteúdos que fundamentaram o protótipo até seu desenvolvimento e posterior avaliação.

4.1 Definição das Diretrizes e Estruturação do Conteúdo

A primeira etapa consistiu na construção das diretrizes que orientaram o desenvolvimento do protótipo educativo. Para isso, realizou-se uma revisão bibliográfica abrangente sobre engenharia de requisitos aplicada a sistemas de aprendizado de máquina, qualidade de dados e uso da gameificação como estratégia educacional. Esse levantamento permitiu identificar conceitos essenciais, desafios recorrentes e recomendações presentes na literatura, fornecendo a base teórica necessária para orientar o conteúdo da plataforma.

A partir dessa revisão, foram definidos os requisitos conceituais que guiariam a elaboração dos *quizzes*, com ênfase

nos critérios fundamentais de qualidade de dados e nas práticas recomendadas para sua definição em projetos de ML. Esses elementos serviram de referência para selecionar os temas a serem abordados e organizar o material de forma progressiva, de modo a favorecer a compreensão dos usuários sobre os principais fatores que influenciam o desempenho e a confiabilidade de modelos baseados em dados.

Com os requisitos estabelecidos, iniciou-se o planejamento do *quiz* educativo, estruturado para apresentar os conteúdos de forma objetiva e interativa. Para isso, os tópicos identificados foram distribuídos em categorias temáticas, apresentadas ao usuário na forma de *cards* interativos, conforme ilustrado na **Figura 1**. Ao selecionar um tema, o participante é direcionado para a tela de conteúdo teórico do respectivo *quiz*, apresentada na **Figura 2**, onde encontra uma explicação estruturada em *Markdown* com os fundamentos necessários para realizar as atividades subsequentes. Essa etapa antecede o início da avaliação prática e exemplifica como a revisão bibliográfica orientou a definição, organização e apresentação dos conteúdos no protótipo.




Figura 1. Ilustração da tela de *quizzes* disponíveis.

4.2 Desenvolvimento do Qualiz

O Qualiz, cujo nome deriva da união entre “qualidade” e “*quiz*”, foi desenvolvido como uma aplicação web responsiva, garantindo uma experiência consistente em dispositivos *notebook* e *mobile*. Sua implementação utilizou ferramentas que possibilitaram a construção de uma interface clara e intuitiva, além de recursos para registrar, armazenar e analisar as respostas dos participantes.

4.2.1 Ferramentas Utilizadas

A camada de front-end foi desenvolvida em React [META, 2024] com TypeScript, utilizando o editor Visual Studio Code. Para a estilização e padronização visual, foram incorporadas as bibliotecas Material UI [MUI Team, 2024] e Google Fonts [Google, 2024], garantindo uma interface responsiva e consistente em diferentes dispositivos.

No back-end, a aplicação utilizou a plataforma ASP.NET

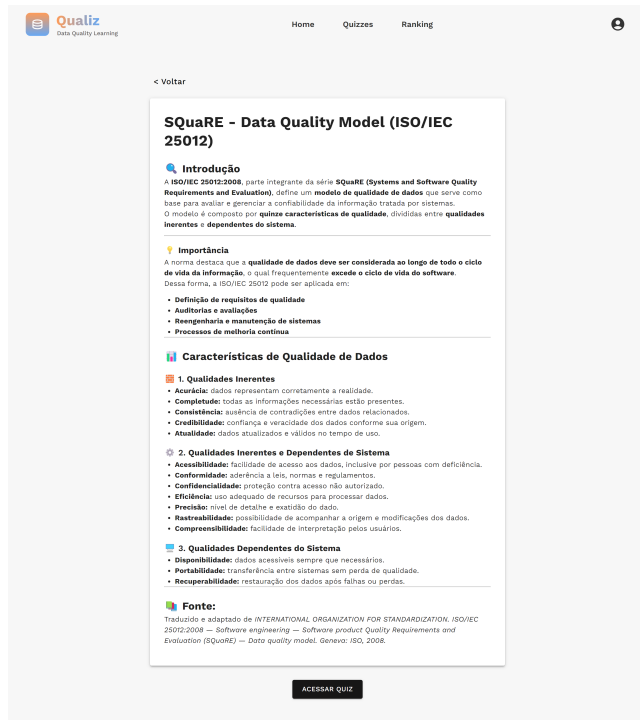


Figura 2. Ilustração da tela do conteúdo teórico de um quiz.

Core, com uma API Web desenvolvida em C# no ambiente Visual Studio. Essa camada é responsável por gerenciar as requisições da interface, processar os dados e coordenar a comunicação com o banco de dados, assegurando a integridade e o fluxo correto das informações.

O armazenamento e gerenciamento dos dados foram realizados utilizando o banco de dados PostgreSQL [The PostgreSQL Global Development Group, 2024]. O versionamento do código-fonte foi conduzido por meio do GitHub [2024], enquanto os testes de integração da API foram realizados com o Postman [2024]. Por fim, o sistema foi hospedado no servidor institucional do Departamento de Ciências de Computação e Estatística da UNESP, permitindo acesso público para avaliação e validação do protótipo.

4.2.2 Principais Funcionalidades

O fluxo de navegação inicia-se com telas de login e cadastro, permitindo criar uma conta ou autenticar-se no sistema. Após o acesso, é possível atualizar as informações pessoais, como nome e senha.

Após a autenticação no sistema, o usuário é direcionado ao *dashboard*, acessível pela aba *Home*, que oferece uma visão geral do desempenho individual. O painel apresenta indicadores como nível atual, pontuação total, *quizzes* concluídos, percentual de progresso, posição no *ranking* e conquistas desbloqueadas. Essa interface permite acompanhar de forma clara e motivadora a evolução do participante ao longo das atividades, conforme ilustrado na Figura 3.

O *ranking* complementa o *dashboard*, permitindo ao usuário comparar seu desempenho com outros participantes. Para constar na lista, é necessário atingir uma pontuação mínima de 300 pontos. A classificação exibe as dez primeiras posições, ordenadas prioritariamente pela pontuação total, seguida pelo nível e pelo número de medalhas conquistadas. Quando o usuário está entre os classificados, sua posição é




Figura 3. Ilustração da tela de *dashboard* do usuário.

destacada visualmente, facilitando a identificação (Figura 4) e incentivando a competição saudável dentro da plataforma.




Figura 4. Ilustração da tela de *ranking*.

Por fim, a aba *Quizzes* organiza os temas em *cards* (Figura 1), permitindo ao participante selecionar o conteúdo desejado e acessar o material teórico correspondente (Figura 2), que antecede a etapa prática. Ao final do material, um botão direciona ao *quiz*, composto por questões de múltipla escolha que podem ser respondidas em qualquer ordem. Conforme ilustrado na Figura 5, cada resposta exibe um *feedback* imediato acompanhado de uma explicação detalhada, reforçando o aprendizado e promovendo uma experiência formativa interativa. Após concluir todas as questões e enviar o *quiz*, o participante visualiza o painel de resumo, que reúne pontuação, número de acertos e conquistas desbloqueadas, representadas na Figura 6.




Figura 5. Ilustração da tela de questões de um quiz.

4.3 Avaliação de Usabilidade

O protótipo e um formulário de avaliação permaneceram disponíveis para testes entre 21 de outubro e 4 de novembro, sendo divulgados em redes sociais e grupos de interesse. Para a avaliação do Qualiz, elaborou-se um questionário composto por 21 afirmações distribuídas em cinco seções temáticas: perfil do usuário, clareza e abrangência do conteúdo teórico,




Figura 6. Ilustração da tela de resumo após finalizar um quiz.

navegabilidade e interface, aspectos motivacionais e elementos de gameificação, e eficácia na transmissão do conhecimento. Cada seção continha três itens avaliados em escala linear de 1 a 5 — variando de “Discordo totalmente” a “Concordo totalmente” — além de uma pergunta aberta opcional para comentários ou sugestões adicionais. Essa configuração permitiu mensurar o grau de concordância dos participantes e identificar contribuições relevantes para o aprimoramento do sistema.

5 Resultados

Nesta seção são apresentados os resultados obtidos a partir da avaliação do Qualiz, considerando as respostas quantitativas e qualitativas dos participantes. A análise baseia-se na média das avaliações individuais para cada afirmativa do questionário, bem como no índice de satisfação associado, permitindo sintetizar as percepções sobre o conteúdo teórico, a usabilidade, os elementos de gameificação e a eficácia geral do sistema, além de evidenciar as principais oportunidades de aprimoramento.

5.1 Perfil dos Participantes

A avaliação contou com a participação de indivíduos majoritariamente vinculados à área de tecnologia. Do total de respondentes, 76% eram do gênero masculino e 24% do feminino. Em relação à faixa etária, predominou o grupo de 18 a 24 anos (60%), seguido por participantes com 45 anos ou mais (20%), entre 35 e 44 anos (16%) e entre 25 e 34 anos (4%), demonstrando diversidade de perfis e níveis de experiência.

Quanto à formação acadêmica, 60% dos participantes estavam cursando o ensino superior, 32% possuíam pós-graduação completa e 8% eram graduados. No aspecto profissional, observou-se uma distribuição variada, destacando-se estudantes (30,8%), estagiários (23,1%), desenvolvedores (11,5%) e professores (11,5%), conforme ilustrado na **Figura 7**.

Os participantes também avaliaram sua experiência prévia envolvendo ML ou IA em uma escala de 1 a 5. A distribuição, apresentada na **Figura 8**, concentrou-se nos níveis intermediários (2 a 4), indicando familiaridade básica ou moderada com o tema, enquanto apenas dois respondentes declararam experiência avançada. Esse perfil demonstra que o público possuía conhecimento suficiente para compreender os conteúdos, ao mesmo tempo em que se encontrava em fase de aprendizagem — característica adequada para avaliar o potencial educativo da ferramenta.




Figura 7. Gráfico com resultado da pergunta: “Qual sua atuação no momento?”.




Figura 8. Gráfico da Experiência prévia com *Machine Learning* ou Inteligência Artificial.

5.2 Clareza e Abrangência do Conteúdo Teórico

A primeira seção do formulário teve como finalidade avaliar a percepção dos usuários quanto à qualidade, compreensão e relevância do material apresentado no protótipo. De acordo com a **Tabela 1**, os resultados indicam um alto nível de aceitação: todas as questões obtiveram médias acima de 4,6 (em uma escala de 1 a 5) e índices de satisfação superiores a 90%, demonstrando que o conteúdo foi considerado claro, acessível e adequado para apoiar o entendimento dos principais conceitos de ER aplicados à qualidade dos dados em *Machine Learning*.

Tabela 1. Resultados sobre a clareza e abrangência do conteúdo teórico.

Afirmção	Média	Satisfação (%)
O conteúdo teórico apresentado foi claro e de fácil compreensão.	4,64	92%
O conteúdo abrangeu de forma suficiente os principais aspectos sobre Engenharia de Requisitos para a qualidade dos dados em ML.	4,64	92%
O protótipo ajudou a compreender melhor a importância da qualidade dos dados no contexto de ML.	4,80	96%

Os comentários abertos enfatizam essa tendência positiva, evidenciando a organização, objetividade e didática do material. Vários participantes mencionaram que a disposição em tópicos, tabelas e formatação facilitou a leitura e a

compreens˜o. Sugest˜es de melhoria incluıram a adi˜˜o de recursos multimıdia — como vıdeos, anima˜es e *links* complementares — para enriquecer a experiˆncia. De modo geral, os resultados indicam que o conteıdo te˛rico cumpriu seu papel formativo e foi bem recebido pelos usuˆrios.

5.3 Navegabilidade e Interface

Objetivando analisar a experiˆncia dos participantes quanto ˆ intera˜˜o com o protˆtipo, esta se˜˜o do formulˆrio visou avaliar a facilidade de uso, a acessibilidade e a ausˆncia de dificuldades tˆcnicas durante a navega˜˜o. Os resultados, apresentados na **Tabela 2**, s˜o amplamente positivos, com mˆdias acima de 4,7 e ındices de satisfa˜˜o entre 94% e 98%, indicando que a interface foi considerada visualmente agradˆvel, a navega˜˜o intuitiva e as dificuldades tˆcnicas praticamente inexistentes.

Tabela 2. Resultados sobre a navegabilidade e interface.

Afirma˜˜o	Mˆdia	Satisfa˜˜o (%)
A interface do protˆtipo ˆ visualmente agradˆvel.	4,88	98%
A navega˜˜o entre as telas e funcionalidades ˆ intuitiva.	4,80	96%
N˜o encontrei dificuldades tˆcnicas ou de usabilidade durante o uso.	4,72	94%

Complementarmente, os comentˆrios destacam a organiza˜˜o clara dos elementos, a estˆtica agradˆvel e a fluidez na intera˜˜o. Como sugest˜o de aprimoramento, foi proposto a inclus˜o de orienta˜es sobre as "regras do jogo". De forma geral, os resultados ressaltam que a plataforma oferece uma experiˆncia de uso eficiente, consistente e satisfatˆria, atendendo aos princıpios de usabilidade e garantindo uma intera˜˜o intuitiva para os usuˆrios.

5.4 Aspectos Motivacionais e Gamefica˜˜o

A fim de avaliar o impacto da gamefica˜˜o sobre o engajamento dos usuˆrios, esta se˜˜o do formulˆrio objetivou analisar como os elementos lıdicos e os mecanismos de *feedback* influenciaram a motiva˜˜o e o interesse pelo aprendizado no protˆtipo. Conforme a **Tabela 3**, os resultados evidenciam mˆdias elevadas, acima de 4,6, e ındices de satisfa˜˜o que variam entre 94% e 98%. Esses valores sugerem que a incorpora˜˜o de mecˆnicas de jogo desempenhou papel relevante na promo˜˜o do engajamento e no estımulos ˆ motiva˜˜o intrınseca dos participantes, tornando a experiˆncia mais interessante e refor˜ando o envolvimento contınuo com as atividades.

Ademais, os comentˆrios refor˜am que o *ranking*, as medalhas e o sistema de *feedback* contribuıram significativamente para o sentimento de progresso e desafio durante o uso do protˆtipo. Entre as sugest˜es de melhoria, destaca-se a necessidade de esclarecer as regras e os critˆrios de pontua˜˜o e participa˜˜o do *ranking*. Em suma, as percep˜es reportadas confirmam que a gamefica˜˜o foi eficaz em tornar o Qualiz mais envolvente e estimulante, promovendo o aprendizado ativo e mantendo o engajamento ao longo das atividades.

Tabela 3. Resultados sobre os aspectos motivacionais e elementos de gamefica˜˜o.

Afirma˜˜o	Mˆdia	Satisfa˜˜o (%)
Os elementos de gamefica˜˜o (como <i>quizzes</i> , medalhas e <i>ranking</i>) tornaram o aprendizado mais interessante.	4,88	98%
Senti-me motivado(a) a continuar explorando o protˆtipo.	4,76	95%
O sistema de <i>feedback</i> (mensagens, pontua˜˜o, conquistas) foi claro e estimulante.	4,68	94%

5.5 Eficˆcia na Transmiss˜o de Conhecimento

Visando avaliar a eficˆcia do Qualiz na transmiss˜o e consolida˜˜o do conhecimento, esta se˜˜o do formulˆrio teve o intuito de examinar o quanto sua utiliza˜˜o contribuiu para o aprendizado efetivo dos participantes. Os resultados da **Tabela 4** apresentam mˆdias superiores a 4,6 e ındices de satisfa˜˜o entre 94% e 95%, indicando que o protˆtipo cumpriu de forma consistente seu papel como recurso de apoio educacional. Em geral, podemos inferir que o sistema contribuiu para a compreens˜o dos principais conceitos, auxiliou na fixa˜˜o do conteıdo e seria recomendˆvel para outras pessoas interessadas no tema.

Tabela 4. Resultados sobre a eficˆcia na transmiss˜o de conhecimento.

Afirma˜˜o	Mˆdia	Satisfa˜˜o (%)
O uso do protˆtipo contribuiu para meu aprendizado sobre Engenharia de Requisitos para a qualidade de dados em sistemas de ML.	4,75	95%
As atividades propostas ajudaram a fixar o conteıdo apresentado.	4,72	94%
Recomendo o uso do protˆtipo para quem deseja aprender sobre o tema proposto.	4,68	94%

Grande parte dos comentˆrios ressalta a dinˆmica atra-tiva e o potencial pedagˆgico da plataforma. Contudo, alguns apontamentos sugerem possibilidades de aprimoramento, como a inclus˜o de elementos visuais adicionais, avatares e atividades interativas mais diversificadas. Assim, o conjunto de avalia˜es e observa˜es confirma que o protˆtipo foi eficaz na transmiss˜o do conhecimento, mantendo um elevado nıvel de aprova˜˜o e revelando oportunidades de expans˜o e refinamento em vers˜es futuras.

O principal objetivo do estudo ˆ investigar como a ER pode contribuir para a promo˜˜o da qualidade de dados, ao mesmo tempo em que explora a gamefica˜˜o como recurso educativo.

6 Conclusão

O presente trabalho demonstrou que o Qualiz cumpriu seu objetivo de apoiar o aprendizado sobre Engenharia de Requisitos aplicada à qualidade de dados em sistemas de *Machine Learning*, ao integrar conteúdo teórico estruturado com elementos de gamificação. Os resultados evidenciaram alta aceitação entre os participantes, que avaliaram positivamente todos os aspectos analisados. Esse desempenho confirma a pertinência da proposta e reforça a viabilidade de abordagens lúdicas e interativas para suprir a carência de ferramentas educacionais voltadas a essa temática ainda pouco explorada na interseção entre Engenharia de Software e Ciência de Dados.

Como contribuição, o estudo apresenta um protótipo capaz de tornar o processo de aprendizagem mais dinâmico, acessível e motivador, favorecendo a compreensão de práticas essenciais para garantir a qualidade de dados em ML. A avaliação dos usuários permitiu identificar não apenas os pontos fortes da aplicação, mas também oportunidades de evolução, delineando com clareza seu potencial pedagógico.

Apesar das avaliações positivas, algumas limitações foram observadas, como o escopo introdutório do conteúdo e o número reduzido de participantes, fatores que restringem a generalização dos resultados. Para mitigar os efeitos de tais limitações, garantiu-se uma estruturação arquitetural em camadas do protótipo para facilitar a sua expansão por meio da inclusão simplificada de novos conteúdos teóricos de interesse, bem como uma diversidade de participantes, abrangendo faixa etária e níveis de atuação e de conhecimento diversificados, para aumentar a representatividade da amostra.

Conforme amplamente discutido na literatura, a qualidade dos dados constitui um requisito fundamental para o sucesso de aplicações baseadas em Inteligência Artificial e aprendizado de máquina, influenciando diretamente o desempenho e a confiabilidade dos modelos. Nesse contexto, destaca-se a necessidade de profissionais capacitados não apenas em técnicas de modelagem, mas também na definição e análise de requisitos relacionados aos dados que alimentam tais sistemas. Entretanto, iniciativas educacionais voltadas especificamente à articulação entre Engenharia de Requisitos e qualidade de dados em ML ainda são limitadas. À luz desse cenário, o Qualiz contribui para mitigar essa lacuna ao apoiar a compreensão de conceitos essenciais e de boas práticas necessárias para enfrentar os desafios inerentes ao tratamento e à utilização de dados em sistemas inteligentes, alinhando-se às recomendações presentes na literatura quanto à centralidade da qualidade de dados no ciclo de vida de soluções baseadas em IA.

Como trabalhos futuros, planeja-se a expansão dos materiais teóricos, a diversificação das atividades e a inclusão de novos elementos visuais e funcionais, como avatares, mídias complementares e instruções sobre as "regras do jogo", esclarecendo a dinâmica da plataforma, em atenção aos comentários dos participantes do processo de avaliação.

Declarações complementares

Contribuições dos autores

Amanda Prampero Paes Mendes foi responsável pela escrita do manuscrito, revisão bibliográfica, desenvolvimento do protótipo, condução do processo de avaliação e análise dos resultados. Rogéria

Cristiane Gratão de Souza revisou o manuscrito, supervisionou a pesquisa, fornecendo direcionamento teórico e metodológico, além de contribuir com trabalhos anteriores que embasaram o estudo. Ambos os autores leram e aprovaram o manuscrito final.

Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses.

Disponibilidade de dados e materiais

Os conjuntos de dados e o código-fonte gerados durante o estudo atual poderão ser disponibilizados, mediante solicitação ao autor principal.

Referências

- Amershi, S. *et al.* (2019). Software engineering for machine learning: a case study. In *2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE SEIP)*, pages 291–300. IEEE. DOI: 10.1109/ICSE-SEIP.2019.00042.
- Atwal, H. (2019). *Practical DataOps: delivering agile data science at scale*. Apress.
- GitHub (2024). Github: Where the world builds software. Disponível em: <https://github.com/>.
- Google (2018). Machine learning crash course. Disponível em: <https://developers.google.com/machine-learning/crash-course>.
- Google (2024). Google fonts. Disponível em: <https://fonts.google.com/>.
- Ibáñez, M.-B., Di-Serio, A., and Delgado-Kloss, C. (2014). Gamification for engaging computer science students in learning activities: a case study. *IEEE Transactions on Learning Technologies*, 7(3):291–301. DOI: 10.1109/TLT.2013.11.
- International Organization for Standardization (2008). ISO/IEC 25012:2008 - software engineering – software product quality requirements and evaluation (SQuARE) – data quality model. Standard ISO/IEC 25012:2008.
- Japiassu, R. B. and Rached, C. D. A. (2020). A gamificação no processo de ensino-aprendizagem: uma revisão integrativa. *Revista Educação em Foco*, 12(1):1–20.
- Kreuzberger, D., Kühl, N., and Hirschl, S. (2023). Machine learning operations (MLOps): overview, definition, and architecture. *IEEE Access*, 11:31866–31879. DOI: 10.1109/ACCESS.2023.3262138.
- Lemos, E. L. *et al.* (2020). AD-RPG: Elicitando requisitos na idade média utilizando um jogo educacional. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação (SBIE 2020)*, pages 1763–1772, Porto Alegre. Sociedade Brasileira de Computação. DOI: 10.5753/cbie.sbie.2020.1763.
- Liberato, E. L. P., Pinheiro, A. G. P., Milanez, A. F., Silva, M. A. F. d., and Silva, P. H. A. d. (2024). Gametest: Um jogo para praticar teste de software. *Informática na Educação: Teoria & Prática*, 27(1):117–133. DOI: 10.22491/1982-1654.138735.
- META (2024). React – the library for web and native user interfaces. Disponível em: <https://react.dev/>.
- MUI Team (2024). Mui: React components for faster and easier web development. Disponível em: <https://mui.com>.

- com/.
- Nakajima, S. and Nakatani, T. (2021). Ai extension of SQuaRE data quality model. In *2021 IEEE 21st International Conference on Software Quality, Reliability and Security Companion (QRS-C)*, pages 306–313. IEEE. DOI: 10.1109/QRS-C55045.2021.00053.
- Pei, Z. *et al.* (2022). Requirements engineering for machine learning: a review and reflection. In *2022 IEEE 30th International Requirements Engineering Conference Workshops (REW)*, pages 2770–2784. IEEE. DOI: 10.1109/REW56159.2022.00039.
- Postman (2024). Postman: Api platform for building and using apis. Disponível em: <https://www.postman.com/>.
- Pressman, R. S. and Maxim, B. R. (2016). *Engenharia de software: uma abordagem profissional*. AMGH, Porto Alegre, 8 edition.
- Rangineni, S. (2023). An analysis of data quality requirements for machine learning development pipelines frameworks. *International Journal of Computer Trends and Technology*, 71(8):16–27. DOI: 10.14445/22312803/IJCTT-V71I8P103.
- Seaborn, K. and Fels, D. I. (2015). Gamification in theory and action: a survey. *International Journal of Human-Computer Studies*, 74(1):14–31. DOI: 10.1016/j.ijhcs.2014.09.006.
- Sommerville, I. (2019). *Engenharia de software*. Pearson, São Paulo, 10 edition.
- Teichner, O. T. and Fortunato, I. (2015). Refletindo sobre a gamificação e suas possibilidades na educação. *Revista Brasileira de Iniciação Científica*, 2(3):102–111.
- The PostgreSQL Global Development Group (2024). PostgreSQL: The world’s most advanced open source database. Disponível em: <https://www.postgresql.org/>.
- Vogelsang, A. and Borg, M. (2019). Requirements engineering for machine learning: perspectives from data scientists. In *2019 IEEE 27th International Requirements Engineering Conference Workshops (REW)*, pages 244–251. IEEE. DOI: 10.1109/REW.2019.00050.